

Luiz Filipe Carreiro Salazar

**Detecção de Estilos de Aprendizagem em
Ambientes Virtuais de Aprendizagem Utilizando
Redes Bayesianas**

Diamantina - MG

2017

Luiz Filipe Carreiro Salazar

Detecção de Estilos de Aprendizagem em Ambientes Virtuais de Aprendizagem Utilizando Redes Bayesianas

Dissertação apresentada ao Programa de Pós-Graduação em Educação da Universidade Federal dos Vales Jequitinhonha e Mucuri como requisito final para a obtenção de Título de Mestre em Educação.

Universidade Federal dos Vales do Jequitinhonha e
Mucuri – UFVJM
Programa de Pós-Graduação em Educação (PPGED)

Orientador: Dr. Luciana Perreira de Assis
Coorientador: Dr. Alessandro Vivas Andrade

Diamantina - MG

2017

Ficha Catalográfica – Serviço de Bibliotecas/UFVJM
Bibliotecário Anderson César de Oliveira Silva, CRB6 – 2618.

S161d

Salazar, Luiz Filipe Carreiro
Detecção de Estilos de Aprendizagem em Ambientes Virtuais de
Aprendizagem utilizando Redes Bayesianas / Luiz Filipe Carreiro
Salazar. – Diamantina, 2017.
72 p. : il.

Orientadora: Luciana Pereira de Assis
Coorientador: Alessandro Vivas Andrade

Dissertação (Mestrado Profissional – Programa de Pós-Graduação
em Educação) - Universidade Federal dos Vales do Jequitinhonha e
Mucuri.

1. Estilos de Aprendizagem. 2. Detecção automática de Estilos de
Aprendizagem. 3. Redes Bayesianas. 4. Ambientes Virtuais de
Aprendizagem. I. Assis, Luciana Pereira de. II. Andrade, Alessandro
Vivas. III. Título. IV. Universidade Federal dos Vales do
Jequitinhonha e Mucuri.

CDD 006.3

Elaborado com os dados fornecidos pelo(a) autor(a).



MINISTÉRIO DA EDUCAÇÃO

UNIVERSIDADE FEDERAL DOS VALES DO JEQUITINHONHA E MUCURI - UFVJM

Pró-Reitoria de Pesquisa e Pós-Graduação - PRPPG

www.ufvjm.edu.br

prppg@ufvjm.edu.br



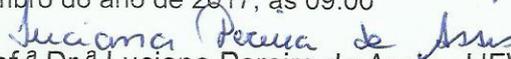
ATA DE DEFESA DE MESTRADO DE LUIZ FILIPE CARREIRO SALAZAR ELABORADA PELA COMISSÃO EXAMINADORA.

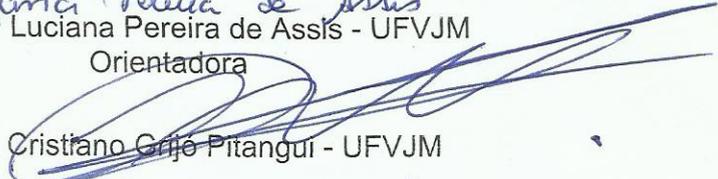
A Comissão Examinadora da Dissertação de MESTRADO do pós-graduando LUIZ FILIPE CARREIRO SALAZAR do Programa de Pós-Graduação em Educação - Stricto Sensu, nível de MESTRADO, área de concentração: Educação e Tecnologias aplicadas em Instituições Educacionais, da Universidade Federal dos Vales do Jequitinhonha e Mucuri - UFVJM, instalou-se no dia 07 de Novembro do ano de 2017, às 09:00, nas dependências da UFVJM, para abertura dos trabalhos e arguição do candidato. A Comissão Examinadora foi composta pelos Professores Prof.^a Dr.^a Luciana Pereira de Assis - Orientadora (UFVJM), Prof. Dr. Cristiano Grijó Pitangui (UFVJM) e Prof. Dr. Leonardo Lana de Carvalho (UFVJM). Iniciou-se a sessão com a apresentação dos componentes da Comissão Examinadora e leitura dos artigos 55 a 60 do Capítulo XV do Regulamento Geral dos Cursos de Pós-Graduação Stricto Sensu/UFVJM e passou-se a palavra ao candidato para apresentação de sua Dissertação intitulada "Detecção de Estilos de Aprendizagem em Ambientes Virtuais de Aprendizagem Utilizando Redes Bayesianas". Após a apresentação oral, o candidato foi arguido pela referida Comissão, obtendo o seguinte resultado:

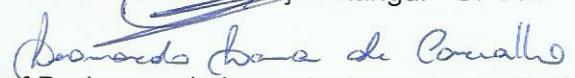
- Aprovado sem ressalvas
- Aprovado com ressalvas
- Reprovado

Em caso de aprovação, o candidato fará jus ao título de MAGISTER SCIENTIAE EM EDUCAÇÃO, pela UFVJM, após a entrega da versão final da dissertação, com as devidas correções, à Secretaria dos Programas de Pós-Graduação e homologação pelo Conselho de Pesquisa e Pós-Graduação.

DIAMANTINA, 07 de Novembro do ano de 2017, às 09:00


Prof.^a Dr.^a Luciana Pereira de Assis - UFVJM
Orientadora


Prof.Dr. Cristiano Grijó Pitangui - UFVJM


Prof.Dr. Leonardo Lana de Carvalho - UFVJM

*Reabido
09/11/17*

Dedico este trabalho a minha família que é o alicerce da minha vida, principalmente a minha esposa e companheira Ticiane e meus filhos Eduarda e Fernando, que por muitas vezes deixaram de ter minha atenção e companhia por causa dos estudos, sempre me incentivando, fazendo parte desta grande jornada.

Agradecimentos

Agradeço primeiramente a Deus por ter me munido de fé e resiliência para vencer mais esse desafio, a toda minha família, aos professores Luciana Assis, Alessandro Vivas e Cristiano Pitangui, aos amigos Samuel Falci, Emerson Bodevan e Camila Gomide pelo apoio e ao IFNMG campus Araçuaí pelo apoio e incentivo para conclusão deste trabalho.

*"A verdadeira medida de um homem não é
como ele se comporta em momentos de conforto e conveniência,
mas como ele se mantém em tempos de controvérsia e desafio".
(Martin Luther King)*

Resumo

O avanço da tecnologia possibilitou o surgimento de ferramentas para o acesso a conhecimento e experiências individuais e coletivas. As Tecnologias da Informação e Comunicação e a internet criaram o conceito chamado Ciberespaço, um local virtual onde o somatório de todas as experiências, saberes e culturas de todos os povos que forma a Inteligência Coletiva. Tal fenômeno contribuiu para o desenvolvimento da Educação à Distância e os Sistemas Inteligentes para Educação. Um dos maiores problemas em EaD é ausência de adaptatividade do ensino ao Estilo de Aprendizagem dos estudantes, que consiste nas preferências que cada aluno tem em receber um determinado conteúdo. Dessa forma, o trabalho aborda uma técnica de Redes Bayesianas para detectar automaticamente os Estilos de Aprendizagem dos estudantes para proporcionar uma oferta de material de ensino adaptado às preferências de aprendizagem nos Ambientes Virtuais de Aprendizagem. O trabalho se baseia em conceitos e técnicas de Inteligência Artificial e Aprendizado de Máquina para compor um modelo computacional e probabilístico de uma Rede Bayesiana para inferir e detectar qual a melhor combinação de Estilos de Aprendizagem. Para estruturar os métodos de detecção dos Estilos de Aprendizagem, a pesquisa utiliza o Modelo de Estilo de Aprendizagem Felder-Silverman. Para representar o comportamento do estudante no Ambiente Virtual Aprendizagem, o trabalho utiliza um sistema para simular o desempenho do estudante em um Sistema de Tutoria Inteligente. Os métodos utilizados resultam na construção de um algoritmo de detecção automática de Estilos de Aprendizagem em Ambientes Virtuais de Aprendizagem. Os resultados do algoritmo de Rede Bayesiana foram comparados aos resultados de outro algoritmo de detecção de Estilos de Aprendizagem na literatura. Nos testes, o algoritmo de Rede Bayesiana se mostrou mais eficiente comparado ao da literatura, diminuindo consideravelmente o número de iterações do sistema que no final converge ao Estilo de Aprendizagem do estudante, diminuindo o tempo de execução e aumentando a precisão dos resultados. O trabalho abre discussão quanto a robustez, eficiência e precisão da aplicação de Redes Bayesianas para detecção de Estilos de Aprendizagem.

Palavras-chave: estilos de aprendizagem. detecção automática de estilos de aprendizagem. redes bayesianas. ambientes virtuais de aprendizagem. educação.

Abstract

The advancement of technology has enabled the emergence of tools for access to knowledge and individual and collective experiences. Information and Communication Technologies and the Internet have created the concept called Cyberspace, a virtual place where the sum of all the experiences, knowledge and cultures of all peoples that forms the Collective Intelligence. This phenomenon contributed to the development of Distance Education and Intelligent Systems for Education. One of the major problems in EaD is the lack of adaptability of teaching to students' learning style, which consists of the preferences each student has in receiving a certain content. Thus, the paper approaches a technique of Bayesian Networks to automatically detect the Learning Styles of the students to provide an offer of teaching material adapted to the preferences of learning in the Virtual Environments of Learning. The work is based on concepts and techniques of Artificial Intelligence and Machine Learning to compose a computational and probabilistic model of a Bayesian Network to infer and detect the best combination of Learning Styles. To structure Learning Styles detection methods, the search uses the Felder-Silverman Learning Style Template. To represent student behavior in the Virtual Learning Environment, the work uses a system to simulate student performance in an Intelligent Tutoring System. The methods used result in the construction of an algorithm for automatic detection of Learning Styles in Virtual Learning Environments. The results of the Bayesian Network algorithm were compared to the results of another learning style detection algorithm in the literature. In the tests, the Bayesian Network algorithm proved to be more efficient compared to the literature, considerably reducing the number of system iterations that in the end converges to the student's Learning Style, reducing execution time and increasing the accuracy of the results. The paper discusses the robustness, efficiency and accuracy of the application of Bayesian Networks for the detection of Learning Styles.

Keywords: learning styles. automatic detection of learning styles. bayesian networks. virtual learning environments. education.

Lista de ilustrações

Figura 1 – Modelo de Sistema Tutor Inteligente	25
Figura 2 – Grafo bayesiano das relações condicionais entre variáveis	38
Figura 3 – Modelo de Cadeia de Markov	43
Figura 4 – Rede Bayesiana para de detecção do EA baseado no FLSM	49
Figura 5 – Rede Bayesiana para detecção do Estilo de Aprendizagem da dimensão Processamento com as relações finais de probabilidades	52
Figura 6 – Cadeia de Markov para seleção aleatória do estilo de aprendizagem . .	55
Figura 7 – <i>Boxplot</i> dos resultados dos algoritmos RB(1) e Dorça (2) referente à métrica Médias das Notas	58
Figura 8 – <i>Boxplot</i> dos resultados dos algoritmos RB(1) e Dorça (2) referente à métrica Quantidade de Notas Insatisfatórias (notas <60).	58
Figura 9 – Desempenho dos resultados dos algoritmos RB(1) e Dorça (2)	60
Figura 10 – Desempenho dos resultados dos algoritmos RB(1) e Dorça (2)	60
Figura 11 – Desempenho dos resultados dos algoritmos RB(1) e Dorça (2)	61

Lista de tabelas

Tabela 1 – Modelo de Estilo de Aprendizagem Felder-Silverman	30
Tabela 2 – Tabela de Simulação de notas com dez registros	50
Tabela 3 – Número de notas abaixo de 60 e média das notas obtidas pelos algoritmos RB(1) e Dorça(2) - Média das 30 execuções	59

Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
AR	Aprendizagem por Reforço
AVA	Ambientes Virtual de Aprendizagem
CAI	Instrução Apoiada por Computador
CEA	Combinação de Estilos de Aprendizagem
DAG	Grafo Dirigido Acíclico
EA	Estilos de Aprendizagem
EaD	Educação a Distância
EC	Estado Cognitivo
FSLSM	Modelo de Estilo de Aprendizagem Felder-Silverman
HMM	Modelos Ocultos de Markov
IA	Inteligência Artificial
LMS	Learning Management Systems
ME	Modelo do Estudante
MP	Modelo Pedagógico
OA	Objetivos de Aprendizagem
P	Probabilidade
PC	Probabilidade Condicional
PESDE	Processo Estocástico de Simulação de Desempenho do Estudante
PFM	Performance do Estudante
PT	Probabilidade Total
RB	Redes Bayesianas
SVM	Máquina de Vetor de Suporte

TIC	Tecnologias da Informação e Comunicação
SAIE	Sistemas Adaptativos e Inteligentes para Educação
SHA	Sistemas Hipermídia Adaptativos
STI	Sistema de Tutoria Inteligente

Sumário

1	INTRODUÇÃO	15
1.1	DEFINIÇÃO DO PROBLEMA	18
1.2	OBJETIVOS	19
1.2.1	OBJETIVO GERAL	19
1.2.2	OBJETIVOS ESPECÍFICOS	19
1.3	ORGANIZAÇÃO DO TRABALHO	19
1.4	Trabalhos Publicados	20
2	REVISÃO DA LITERATURA	21
2.1	AMBIENTES VIRTUAIS DE APRENDIZAGEM	21
2.2	SISTEMAS INTELIGENTES NA EDUCAÇÃO	22
2.3	SISTEMA DE TUTORIA INTELIGENTE	23
2.4	MODELO DO ESTUDANTE	27
2.5	ESTILO DE APRENDIZAGEM	28
2.6	MODELO DE ESTILO DE APRENDIZAGEM FELDER-SILVERMAN	29
2.7	DETECÇÃO DE ESTILO DE APRENDIZAGEM	31
3	REFERENCIAL TEÓRICO	36
3.1	INFERÊNCIAS PROBABILÍSTICAS	36
3.2	METAHEURÍSTICA BAYESIANA	37
3.3	REDES BAYESIANAS	37
3.4	CADEIA DE MARKOV	42
3.5	INTELIGÊNCIA ARTIFICIAL	43
3.6	SISTEMAS ADAPTATIVOS E INTELIGENTES PARA EDUCAÇÃO (SAIE)	45
4	METODOLOGIA	48
4.1	ALGORITMO PROPOSTO	48
4.1.1	PROPOSTA BAYESIANA	48
4.1.2	FUNCIONAMENTO DO ALGORITMO	52
5	RESULTADOS	57
6	CONCLUSÃO	62
6.1	CONTRIBUIÇÕES	62
6.2	TRABALHOS FUTUROS	63

REFERÊNCIAS **65**

1 Introdução

Com o advento da tecnologia, a humanidade passou a ter mais acesso a informação através de mídias mais atraentes como jornal, revistas, rádio, cinema e TV. Com tudo, tais recursos não ofereciam forte interação entre as partes envolvidas.

Os fluxos de informação são facilitados em consequência da revolução digital, promovendo maior inclusão e inovação nos diversos setores da economia, sociedade e política. As formas de acesso aos fluxos de informação são diversas e suas exposições ocorrem materializadas por meio de interações entre imagens, sons e textos.

As informações podem ser armazenadas e transmitidas por meio de uma plataforma de interação virtual, conectando e trocando experiências, ensinamentos e aprendizados entre povos e culturas diferentes. Recursos digitais como fóruns, *chats*, *blogs*, redes sociais, repositórios de vídeos e toda a rede de conectividade global criaram conceitos chamados Inteligência Coletiva e Ciberespaço (LÉVY; COSTA, 1993). A Inteligência Coletiva é uma oportunidade de tornar democrático os conhecimentos e os saberes individuais e coletivos (LÉVY; OTTAWA, 2006).

Lévy e Ottawa (2006) ainda salienta que o conhecimento coletivo se torna possível a partir da implementação de Tecnologias da Informação e Comunicação (TICs), a qual desenvolve a conexão entre dispositivos computacionais e indivíduos. Com o advento das TICs abriu-se espaço para o desenvolvimento do ciberespaço, constituinte de uma estrutura de tecnologias capaz de conectar computadores mundialmente. Intercomunicando informações, o ciberespaço integra usuários de todos os lugares rompendo barreiras geográficas.

Nesse contexto, Lévy e Ottawa (2006) expõe que o ciberespaço envolve um espaço de interação entre usuários, em que as informações são transmitidas de forma digital desencadeando um sistema de relações virtuais entre os indivíduos que acessam o ciberespaço. Vale salientar que esse fenômeno contribui para o desenvolvimento humano em diversas áreas importantes. Dentre elas, essa pesquisa direciona seu foco para o ambiente de aprendizagem, o qual apresenta novas formas de ensino virtual, oferecendo modelos de educação estruturados para institucionalizar e formalizar a educação no ambiente virtual do ciberespaço, caracterizando uma Comunidade Virtual de Aprendizagem.

Segundo Hunter (2002), Comunidade Virtual de Aprendizagem é definida como um grupo de pessoas interagindo no ciberespaço, adquirindo conhecimento coletivo dos participantes e contribuindo com experiências individuais, a um grupo de interesses em comum. Uma característica de uma Comunidade Virtual de Aprendizagem é a necessidade de ser colaborador e não apenas consumidor dos recursos ou núcleo de conhecimento. As

Comunidades Virtuais de Aprendizagem favorecem a Educação à Distância.

A Educação a Distância (EaD) é a modalidade educacional na qual a mediação didático-pedagógica nos processos de ensino e aprendizagem ocorre com a utilização de meios e tecnologias de informação e comunicação, com estudantes e professores desenvolvendo atividades educativas em lugares ou tempos diversos, de acordo com o decreto lei nº 5.773 de 9 de maio de 2006 (BRASIL, 2006).

A EaD se tornou mais popular graças a um montante de oportunidades tecnológicas oferecidas pelo ciberespaço, envolvendo um processo de ensino-aprendizagem, em que professores e alunos estão distantes geograficamente e são mediados por tecnologia. Mas ao longo do tempo a modalidade de ensino EaD sofreu críticas no que se refere a qualidade de ensino. Para Belloni (2006), a complexidade é muito alta em EaD no que se refere a interação entre professor e estudante, onde tal interação ocorre de maneira indireta no espaço e tempo, gerando um conceito subjetivo de mediação. O maior problema na EaD é a ausência física da mediação pedagógica entre professor e aluno como nos modelos tradicionais de ensino.

Em ambientes de EaD, o termo aluno não é utilizado para definir o participante na jornada educacional, mas sim a nomenclatura estudante. De acordo com Piazzzi (2007), o termo aluno se aplica àquele que se encontra em uma sala de aula, em uma atividade coletiva passiva. Já a definição de estudante se aplica àquele que busca adquirir conhecimento através de suas próprias ações e intenções, sendo uma atividade realizada na maioria das vezes de forma individual ativa.

Para García et al. (2007), os estudantes são caracterizados por diferentes estilos de aprendizagem, com foco em diferentes tipos de informação e processos realizados de maneiras diferentes. Estilos de aprendizagem são as maneiras preferenciais que um indivíduo possui para melhor aprender um determinado conteúdo (DUNN; DUNN, 1978). Uma das características desejáveis de um sistema de educação em EaD é que todos os estudantes possam aprender, apesar de seus estilos de aprendizagem diferentes.

Belloni (2006), ainda pontua um grande problema em EaD, que é quanto ao material didático oferecido. Todos os estudantes de um mesmo curso utilizam um material padronizado, contendo as mesmas abordagens didáticas-pedagógicas, homogeneizando o ensino e não observando as características individuais dos estudantes.

Para Maciel e Backes (2012), objetos de aprendizagem englobam recursos digitais interativos, dinâmicos e reutilizáveis, aplicáveis em diferentes ambientes de aprendizagem. São apresentados em formas de mídias digitais como vídeos, imagens, áudios, textos, gráficos, tabelas, esquemas, tutoriais, aplicações, mapas, jogos educacionais, animações, infográficos e páginas web. Objetos de Aprendizagem possuem flexibilidade suficiente para se adaptarem em diferentes ambientes para melhor atender demandas específicas entre

outros módulos ou cursos diferentes.

A aplicação dos Objetos de Aprendizagem para gerar melhor entendimento de um tema entre estudantes oferece uma oportunidade de Aprendizado Adaptativo. Segundo Dorça et al. (2012), o Aprendizado Adaptativo ou a Educação Adaptativa, é um conjunto de características e estratégias pedagógicas disponíveis em um sistema que possibilita um aprendizado mais eficiente em grupos de estudantes heterogêneos. Isso justifica a preocupação em oferecer mídias adaptadas ao Estilo de Aprendizagem do Estudante, chamados Sistemas de Aprendizagem Adaptativos.

De acordo com Dorça et al. (2012), uma característica moderna de um curso em EaD é a assistência personalizada e inteligente, para atender os estudantes que apresentam perfis e necessidades diferentes. Em virtude disto, um desafio em pesquisa é o desenvolvimento de ferramentas educacionais computadorizadas que possam oferecer algum grau de inteligência e adaptatividade ao estudante.

Para Specht e Oppermann (1998), existe uma diferença entre os conceitos de adaptabilidade e adaptatividade. Adaptabilidade é a capacidade do sistema permitir que o usuário altere parâmetros e configurações para que o mesmo se torne mais adaptável. Já adaptatividade é a capacidade do sistema se adaptar às necessidades do usuário automaticamente, com base em suas necessidades.

Segundo Dorça et al. (2012), um curso de EaD deve ser oferecido em um ambiente inteligente, capaz de promover a detecção automática e dinâmica de estilos de aprendizagem do estudante, de modo a fornecer resultados que justifiquem a oferta de recursos didáticos, pedagógicos e práticas docentes mais personalizados para aperfeiçoar o aprendizado, apoiado por um Ambiente Virtual de Aprendizagem.

Os Ambientes virtuais de aprendizagem (AVA) são um conjunto de softwares que auxiliam na mediação do conhecimento e gestão pedagógica, disponibilizando para seus usuários ferramentas para o ensino e aprendizado em cursos realizados pela internet (RIBEIRO; MENDONÇA; MENDONÇA, 2007). Uma das características de um AVA é apoiar alunos e professores na realização de um curso, permitindo o acompanhamento integral do processo educacional.

De uma forma genérica, os programas de EaD utilizam os sistemas de gestão de aprendizagem, também conhecidos como *Learning Management Systems* (LMS), que tem como principal objetivo apoiar e auxiliar aos professores no trabalho de tutoria nos AVAs. Contudo, tais sistemas não estão preparados para oferecer cursos *on-line* que observam as características individuais dos estudantes, realizando uma formação generalizada dos conceitos sem oferecer qualquer adaptatividade aos Estilos de Aprendizagem dos estudantes (GRAF; KINSHUK, 2006).

Observar as características de aprendizagem do estudante em AVA vai de encontro

às mais modernas teorias pedagógicas. Brusilovsky e Milán (2007) afirmam em seu trabalho que considerar as características de aprendizagem dos estudantes através de um sistema de aprendizagem adaptativo combate a problemática de adequação de cursos, políticas de aprendizagem e material didático ofertadas aos estudantes

Por tanto, o presente trabalho tem como objetivo principal, criar condições favoráveis de adaptatividade em AVAs, caracterizando um Sistema de Aprendizagem Adaptativo, onde será apresentado um algoritmo que detecta automaticamente o Estilo de Aprendizagem do estudante utilizando técnicas de Redes Bayesianas.

Tal proposta abrirá precedentes para reconhecer qual é o Estilo de Aprendizagem do estudante e permitirá a oferta de Objetos de Aprendizagem, ou seja, materiais didáticos adaptados às preferências de aprendizagem dos participantes de cursos em EaD.

1.1 DEFINIÇÃO DO PROBLEMA

Uns dos maiores problemas em EaD é a evasão dos estudantes. Essa problemática é retratada no último Censo Anual da Ead no Brasil em 2015, que 40% das instituições de ensino que ofertam cursos na modalidade à distância, apresentam uma taxa de 26% a 50% de evasão (ABED, 2015). De acordo com Coelho (2002), dentre os principais motivos de desistências de estudantes em EaD estão a dificuldade de adaptação à modalidade de ensino e aos materiais didáticos ofertados. RAMOS (2016) destaca a importância de implementar métodos inovadores que aumente a atração dos cursos de EaD entre os participantes, bem como investimentos diferenciados no ensino para melhor aproveitamento e a permanência dos estudantes.

Os sistemas tradicionais de ensino à distância normalmente oferecem a mesma estrutura didática e pedagógica para todos os matriculados, não observando as características e preferências pessoais dos estudante, tornando um curso genérico e pouco atrativo.

Diversos autores que serviram de referência neste trabalho defendem uma abordagem adaptativa no processo de ensino na modalidade à distância e propõem soluções que podem diminuir as problemáticas em EaD.

Neste contexto, observa-se a necessidade de oferecer um sistema adaptativo que sirva de suporte às plataformas de ensino à distância e que gere apoio às atividades acadêmicas dos estudantes, se adequando as suas necessidades individuais de aprendizado para que possibilite a oferta de material didático e pedagógico coerente ao seus estilos de aprendizagens, detectando e atualizando automaticamente suas preferências no aprendizado.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Apresentar um algoritmo capaz de identificar as preferências individuais e cognitivas de aprendizagem do estudante e atualizar seu estilo de aprendizagem probabilístico, utilizando Redes Bayesianas, suportado pelos conceitos do Modelo de Estilo de Aprendizagem Felder-Silverman (FSLSM), para a seleção de um conjunto de estilos de aprendizagens. A detecção do Estilo de Aprendizagem é importante no contexto educacional pois auxilia na oferta de um material adaptado ao estilo de aprendizagem do estudante, aumentando seu rendimento no processo de aprendizado e possibilitando a diminuição do número de evasão nos cursos de EaD.

1.2.2 OBJETIVOS ESPECÍFICOS

- I. Fazer uma revisão bibliográfica dos conceitos principais que cercam os sistemas inteligentes e adaptativos aplicados à educação à distância com o objetivo de gerar uma atualização e entendimento acerca do assunto, bem como nortear os procedimentos de pesquisa;
- II. Propor um método de detecção e seleção de estilos de aprendizagem do estudante em ambientes virtuais de aprendizagem utilizando o conceito de Redes Bayesianas, com o objetivo de fornecer informação mais precisas sobre o aprendiz, possibilitando uma melhor decisão sobre as políticas de aprendizagem; e
- III. Avaliar o método proposto comparando seu desempenho a de outro método existente na literatura, a fim de provar a otimização e alto desempenho das Redes Bayesianas aplicadas em detecção de estilos de aprendizagem.

1.3 ORGANIZAÇÃO DO TRABALHO

Esta dissertação apresenta em seu segundo capítulo conceitos e autores que fundamentam a dinâmica dos sistemas inteligentes e adaptativos aplicados à educação à distância, uma revisão sobre estilos de aprendizagem e suas ferramentas de detecção automática.

O terceiro capítulo descreve sobre o método proposto para detecção e correção automática e dinâmica dos estilos de aprendizagem em AVAs.

O quarto capítulo define a metodologia utilizada para validação da abordagem, além do algoritmo de Rede Bayesiana, que é o elemento central da proposta de detecção e atualização do estilo de aprendizagem probabilístico.

O quinto capítulo relata os experimentos realizados e resultados obtidos no processo de simulação.

As considerações finais e as propostas para trabalhos futuros são apresentadas no sexto capítulo.

1.4 Trabalhos Publicados

Durante a elaboração desta dissertação, o seguinte trabalho foi produzido:

- I. SALAZAR, L. F. C.; ASSIS, L. P.; ANDRADE, A. V.; PITANGUI, C. G.; CARVALHO, L.L.; FALCI, S.H.; Detecção de Estilos de Aprendizagem em Ambientes Virtuais de Aprendizagem Utilizando Redes Bayesianas. *In: XXVIII Simpósio Brasileiro de Informática na Educação*, 2017, Recife-PE.

O artigo trata da abordagem descrita nesta dissertação.

2 REVISÃO DA LITERATURA

Recentemente, muitas pesquisas estão sendo desenvolvidas no intuito de promover uma melhoria em cursos de EaD, bem como aplicações que detectam perfis mais detalhados de seus usuários para aplicação de uma política de ensino mais adaptada aos estudantes. A seguir, serão apresentados conceitos, teorias e fundamentos aplicados ao processo educacional que basearam esta pesquisa, fundamentalmente no ambiente virtual e tecnológico.

2.1 AMBIENTES VIRTUAIS DE APRENDIZAGEM

O avanço e o desenvolvimento tecnológico impulsionaram e transformaram os sistemas de educação. Somado a isso, o mundo globalizado e a complexidade de tarefas que envolvem informação e tecnologia fazem com que o processo educativo não possa ser considerado uma atividade tradicional, atendendo um maior número de pessoas de diferentes faixas etárias (PEREIRA; SCHMITT; DIAS, 2007).

Conceitualmente, Ambientes Virtuais de Aprendizagem (AVA) consistem em mídias que utilizam o ciberespaço para fornecer conteúdos didáticos promovendo interação viabilizando o processo educativo. Porém, a qualidade do processo educativo depende de fatores como envolvimento do aprendiz, da proposta pedagógica, dos materiais veiculados, estrutura e qualidade dos profissionais envolvidos, monitores e equipe técnica, assim como das ferramentas e recursos tecnológicos aplicados ao ambiente (ALMEIDA, 2003).

Segundo Tajra (2011), os Ambientes Virtuais de Aprendizagem (AVAs) são descritos como aplicativos didáticos que permitem uma maior integração e comunicação entre estudantes e professores, mediado através das tecnologias disponíveis. Eles são considerados como um grupo de TICs que, reunidos, podem transmitir e gerenciar com maior qualidade informações e materiais indispensáveis para a formação de estudantes que fazem uso desse recurso.

AVAs estão sendo cada vez mais utilizados no âmbito acadêmico e corporativo como uma opção tecnológica para atender esta demanda educacional, pois segundo Morais e Cabrita (2008) consistem em uma opção de mídia que está sendo utilizada para mediar o processo ensino-aprendizagem a distância. .

De acordo com Nunes et al. (2012) uma das principais características desses ambientes de ensino é a capacidade de proporcionar uma aprendizagem colaborativa, que é caracterizada pelo conhecimento, experiência e inteligência acumulada entre um grupo de indivíduos que estão inseridos no mesmo processo de ensino, interagindo de forma direta

ou indireta.

De outra forma, [Milligan \(1999\)](#) define AVA como um software instalado em um servidor e programado para gerenciar e administrar os aspectos diversificados de aprendizagem, disponibilizando conteúdos, acompanhando o estudante, avaliando-o e avaliando o processo de ensino-aprendizagem.

De uma forma mais ampla, os AVAs se destacam como sistemas de interatividade tecnológica que facilitam o processo de EaD, proporcionando formas diferentes da construção educacional. Neste sentido, [Vaz, Zanella e ANDRADE \(2010\)](#) consideram um AVA como sistema abrangente e interconectado, que proporciona a integração entre professores e estudantes, mesmo estando distantes fisicamente.

Atualmente, existe grande variedade de sistemas que utilizam a internet para gerar uma interação virtual, oferecendo cursos e permitindo interação entre os participantes através de aulas não presenciais. Tais sistemas evoluem acompanhando o processo de expansão tecnológica, tornando uma estrutura eficiente nas atividades educacionais. Como exemplo de AVAs encontrados em uso pode-se citar: Moodle, TelEduc, Solar, AulaNet, Sócrates, Amadeus, Eureka e Amadeus.

Concluindo, AVAs são sistemas em que alunos e professores podem montar e participar de atividades, aulas e cursos online, oferecendo um ambiente participativo, onde existem discussões, trabalhos, conferências, entre outros, dinamizando e favorecendo a EaD, que é o principal sistema beneficiado por esse advento.

2.2 SISTEMAS INTELIGENTES NA EDUCAÇÃO

Geralmente, *e-learning* é utilizado para melhorar a eficiência educacional por meio de informações e tecnologia de comunicação ([EUSTACE, 2003](#)). Inicialmente a aprendizagem eletrônica, contava com mídias tradicionais como CDs e aplicações web, para compor seu sistema de aprendizagem. Porém, tais tipos de mídias eram estáticas, possuindo um mesmo conteúdo que era visualizado por diferentes tipos de aprendizes.

Com a evolução da internet e suas consequências, como as mudanças no paradigma ensino-aprendizagem, os aprendizes passam a procurar novos meios para obter conhecimento. Um exemplo são as plataformas de ensino à distância, que passaram a disponibilizar conteúdos via web, permitindo que os alunos aprendam os mais variados temas com uma acessibilidade muito maior do que os cursos presenciais.

As escolas e, principalmente, as universidades estão investindo em formas diversas de ensino, através da utilização do computador, da Internet, apoiando cursos a distância ([CANDOTTI et al., 2006](#)). Devido à alta procura destas novas modalidades de ensino, pesquisas foram iniciadas para aprimorar a forma de apresentar o conteúdo aos alunos

para que este obtivesse um melhor rendimento na sua aprendizagem.

Sendo assim, foi inevitável o surgimento de sistemas que atendessem individualmente as necessidades de cada aprendiz e parte destes sistemas utilizam as chamadas hipermídias adaptativas, sendo classificados então como Sistemas de Hipermídia Adaptativa (SHA). Tais sistemas conseguem adaptar o seu conteúdo e mostrar ao aprendiz somente informações relevantes a ele, em determinado momento da sua interação com o mesmo.

Os SHA constroem um modelo dos objetivos, preferências e conhecimento dos indivíduos e utilizam estas informações relacionadas à interação com o sistema para adaptar o conteúdo de acordo com o usuário (BRUSILOVSKY, 2000). Ainda segundo o autor, os sistemas de hipertexto ou hipermídia adaptativa precisam refletir um mínimo de características de diferentes usuários para proporcionar modelos adaptados à diferentes necessidades, preferências e desejos de cada usuário.

Como descrito na introdução deste trabalho, a EaD é uma oportunidade para muitos, porém não oferece recursos atrativos de adaptatividade aos seus participantes. De acordo com Dorça et al. (2012), os estudantes que participam desta modalidade de ensino apresentam perfis diferenciados, onde o conteúdo de um curso pode ser formulado para um determinado perfil de estudante mas não atendendo aos perfis de outros.

Baseado nesse contexto, nos últimos anos surgiram tendências e conceitos de sistemas capazes de personalizar o processo de aprendizagem, introduzindo a adaptatividade do conteúdo didático em tais sistemas, dando origem aos Sistemas Adaptativos e Inteligentes para Educação (SAIE)(BRUSILOVSKY; PEYLO, 2003).

Graf e Kinshuk (2006) é um dos autores que mais contribuiu para a adaptação dos sistemas inteligentes em educação. Para ele, é essencial a aplicação dos Estilos de aprendizagem em sistemas de ensino para promover maior adaptatividade do todo o material didático garantindo a personalização do ensino (GRAF; KINSHUK, 2006). De acordo com Graf (2009), a aplicação de sistemas automáticos e inteligentes na educação evita auto concepções imprecisas ou inconsistentes, permitindo ao estudante concentrar esforços para a aprendizagem sem se preocupar em informar suas preferências.

Um dos modelos de Sistemas Inteligentes na Educação é o Sistema de Tutoria Inteligente, que contextualiza um método de operação e define diretrizes para o funcionamento de um sistema adaptativo aplicado à educação.

2.3 SISTEMA DE TUTORIA INTELIGENTE

A tecnologia avançou ao longo do tempo juntamente com a capacidade cognitiva do ser humano e ao que tudo indica, continuará avançando por tempo indeterminado. Ao lado desse avanço, novas formas de pensar, agir, ensinar e aprender tem gerado mudanças

profundas no cotidiano das pessoas (BORGES, 2005).

Assim, a utilização de recursos computacionais em ambientes educacionais teve início com o surgimento dos sistemas de Instrução Apoiada por Computador (CAI), que fazem uso de métodos tradicionais de ensino, onde a informação segue apenas um sentido: da máquina para o estudante (PHOBUN; VICHEANPANYA, 2010). A partir de então, pesquisadores buscavam melhores formas de representar o conhecimento dentro desse tipo de sistema, até que surgiram os Sistemas Tutores Inteligentes (STIs), que de acordo com Palomino e Others (2013) são sistemas capazes de decidir qual conteúdo deve ser passado e a forma como esse conteúdo deve ser passado.

De acordo com Brusilovsky (2000), a tarefa mais importante dos Sistemas Tutores Inteligentes (STIs) era dar suporte ao estudante no processo de solução de problemas. Para Martins et al. (2007), STIs são sistemas que fornecem o conteúdo de forma personalizada ao estudante, em que para isso são levados em consideração o conhecimento que o estudante já possui, seu conhecimento sobre o ambiente e suas capacidades cognitivas.

Percebe-se que os STIs já dispunham de recursos que os colocavam a frente dos sistemas CAI, de modo que o principal deles é armazenar no Modelo do Estudante (ME) características e preferências dos estudantes, as quais são levadas em consideração no momento em que o conteúdo é selecionado para ser apresentado (PHOBUN; VICHEANPANYA, 2010).

Um STI tem como principal objetivo realizar a tarefa de ensino de um dado conteúdo (domínio) na forma mais adaptada às necessidades individuais do aluno. Assim, a utilização de recursos computacionais em ambientes educacionais teve início com o surgimento dos sistemas de CAI, que fazem uso de métodos tradicionais de ensino, onde a informação segue apenas um sentido: da máquina para o estudante (PHOBUN; VICHEANPANYA, 2010).

A partir de então, pesquisadores buscaram melhores formas de representar o conhecimento dentro desse tipo de sistema, até que surgiram os STIs, que de acordo com Dorça et al. (2012), são sistemas capazes de decidir qual conteúdo deve ser passado e a forma como esse conteúdo deve ser passado. Wenger (1987) descreve STI como um sistema que é capaz de acompanhar o estudante ao longo do processo de aprendizagem, amparando na solução de problemas, utilizando um ambiente computacional de aprendizagem que possui modelos de conteúdo e estratégias pedagógicas que especificam o que e como ensinar. Para Martins et al. (2007), STIs são sistemas que fornecem o conteúdo de forma personalizada ao estudante, em que para isso são levados em consideração o conhecimento que o estudante já possui, seu conhecimento sobre o ambiente e suas capacidades cognitivas.

De acordo com Brusilovsky (2000), a tarefa mais importante dos STIs era dar suporte ao estudante no processo de solução de problemas. Os STIs possuem duas im-

portantes características que é o sequenciamento personalizado de conteúdo e o suporte interativo à solução de problemas. Tais características promovem a diferença entre os STIs dos demais sistemas tradicionais, tendo em vista a aplicação de técnicas inteligentes que simulam a figura do tutor nos ambientes de ensino tradicionais (BRUSILOVSKY, 1996).

Segundo a abordagem de Wenger (1987), a arquitetura de um Sistema Tutor Inteligente pode ser definida por quatro módulos distintos:

- **Módulo Especialista:** Analisa as habilidades do estudante junto com seu Estilo de Aprendizagem e oferece material adaptado do Módulo Pedagógico levando em consideração as soluções proposta pelo tutor. Possui o conhecimento sobre as estratégias e táticas para selecioná-las em função das características do estudante (representadas no Módulo do Estudante);
- **Módulo do Estudante:** Armazenamento dos dados do estudante bem como seus estilos de aprendizagem, habilidades cognitivas, desenvolvimento e evolução do indivíduo. Neste módulo estão armazenadas/modeladas as características individuais do aluno (conhecimento individual sobre o domínio, por exemplo);
- **Módulo Pedagógico:** Oferece ao estudante material personalizado e adaptado às suas preferências de aprendizagem. Detêm o conhecimento sobre a matéria no formato de regras de produção, estereótipos, OA, etc.;
- **Módulo de Interface:** Fornece interação dinâmica e personalizada com o Estudante. Intermedia as ações entre o tutor e o aluno.

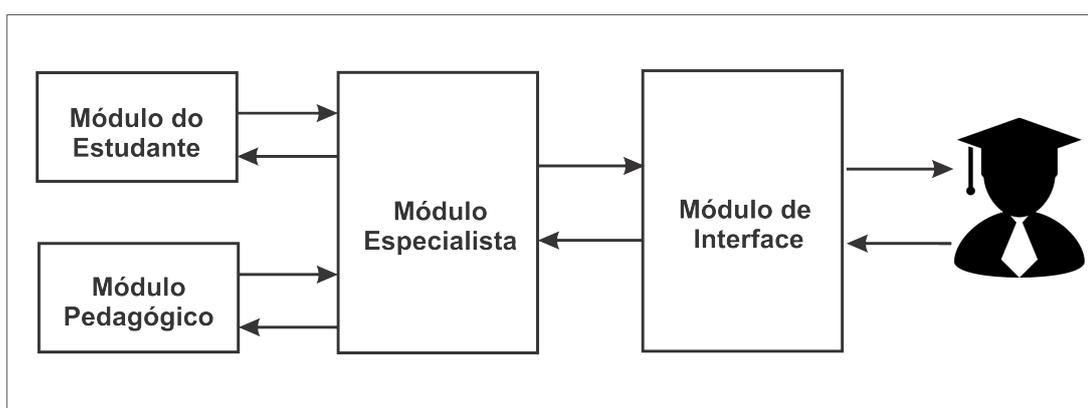


Figura 1 – Modelo de Sistema Tutor Inteligente

De acordo com a figura 1 o estudante utiliza o STI de forma interativa e da mesma forma recebe orientações sobre a sua dinâmica de estudo pelo Módulo de Interface.

O Módulo de Interface está mais voltado para a comunicação com o estudante. Uma questão muito debatida quanto a esse módulo é a forma de implementação da interface de

comunicação entre o sistema e o estudante. [Costa et al. \(1999\)](#) aborda tal dificuldade em definir qual metáfora virtual o estudante se adapta melhor. A aposta é na variedade de tecnologias para esse fim, abordando desde simples caixas de diálogo à linguagens naturais e reconhecimento de voz, para extrair e ofertar a maior quantidade de informações do estudante.

O Módulo Especialista deve ter acesso a todos os módulos do sistema para traçar o domínio do conhecimento do estudante, utilizando informação do Módulo do Estudante tal como EA e se conecta ao Módulo Pedagógico para determinar qual será a melhor proposta de aprendizado para o perfil do estudante. Segundo [Wenger \(1987\)](#), o módulo de Especialista utiliza dados estatísticos sobre o comportamento do estudante no STI, como por exemplo soluções utilizadas pelo estudante para resolver problemas, comparados com informações relativas às mediações do tutor com o estudante.

O Módulo do Estudante armazena as informações específicas do estudante, tais como histórico de notas, aproveitamento em atividades e exercícios, preferências no acesso ao sistema, preferências em utilizar recursos de sistema, etc. [Brusilovsky \(2000\)](#) ressalta a importância do Módulo do Estudante para o funcionamento de um STI pois, de acordo com suas informações, será definido o perfil do estudante para que viabilize a adaptatividade das políticas de ensino.

O Módulo Pedagógico armazena uma grande e variada quantidade de material de domínio, múltiplas estratégias pedagógicas, modelos esquemáticos, regras de aplicação didáticas, informações de estereótipos regionais entre outros recursos a serem oferecidos ao Módulo Especialista. Exemplos, questões problemas, dentre outros viabilizam uma gama de oportunidades para a oferta de material adaptado às preferências do estudante em forma de AO ([DUTRA; TAROUCO, 2006](#)).

Desta forma, o desenvolvimento de um sistema computacional que auxilie na identificação do estilo de aprendizagem do aluno será de grande utilidade para modelagem do estudante, que é abordado nesta proposta como problema de pesquisa. Tal modelo precisa de informações precisas sobre o tipo de aprendizagem do estudante para que os modelos sejam gerados com maior precisão.

O funcionamento desses quatro componentes, aliados a técnicas e métodos específicos permitem que sistemas forneçam o conteúdo de forma adaptada as necessidades do estudante.

Por tanto, considerar processos sistemáticos e tecnológicos na modelagem do estudante e no fornecimento da adaptatividade no ensino é essencial para tornar o processo de aprendizagem mais adequando ao estudante.

2.4 MODELO DO ESTUDANTE

Uma característica importante nos sistemas inteligentes para educação é a capacidade de adaptação do mesmo às particularidades do estudante (VALLDEPERAS,). Como visto, a dificuldade de criar um sistema adaptável às preferências e objetivos pessoais é grande pois o comportamento do estudante durante a sessão de aprendizagem é não determinístico (LO; CHAN; YEH, 2012).

O Modelo do Estudante (ME) é uma representação efetiva do conhecimento atualizado do estudante dentro de um domínio específico. Segundo Thompson (1996), essa questão é muito relevante para o processo de adaptação no processo educacional.

É imprescindível que o ME detenha e administre as principais informações sobre o estudante, inclusive as que possuem pouco valor. Para Botelho et al. (2009), o ME precisa representar de forma bem específica a personalidade educacional do estudante, bem como seu conhecimento, preferências, EA, motivações, características pessoais, crenças e objetivos de aprendizagem.

Em seu trabalho, Graf (2009) aborda dois conceitos para se obter informações para compor o ME: o colaborativo e o automático. O conceito colaborativo faz uso de um processo chamado ILSQ - Index of Learning Style Questionary, desenvolvido por Soloman e Felder (1999), onde se faz a aplicação de um questionário psicométrico preenchido pelos estudantes, recolhendo informações para a criação do ME. No conceito automático, a construção do ME é elaborado automaticamente, levando em consideração o comportamento do estudante mediante a utilização do sistema.

Neste contexto, o conceito automático teoricamente é mais seguro e preciso que o colaborativo. De acordo com Graf (2009) o conceito automático é livre de preconceitos e de concepções duvidosas, ao contrário do conceito colaborativo que podem conter resposta contraditórias e inconsistentes. Outra vantagem do conceito automático é a de permitir que o estudante não se preocupe com o fornecimento de dados e o libere para as atividade de aprendizagem. E por fim, a atualização constante do ME pelo conceito automático é mais eficiente frente a coleta de dados em um momento específico no conceito colaborativo.

Dorça et al. (2012) em seu trabalho apresenta uma abordagem probabilística, fazendo uso de uma técnica de aprendizagem por reforço, usando o algoritmo *Q-learning* para criar o ME. O modelo é determinado de forma interativa e dinâmica, em um processo estocástico, agrupando uma combinação dos objetivos de aprendizagem, EA e nível cognitivo do estudante, utilizando o modelo FSLSM adaptado a uma Cadeia de Markov.

Dorça et al. (2012) utiliza uma abordagem para modelagem do estudante baseado na Taxonomia de Bloom, para medição do conhecimento considerando os valores de nível de conhecimento do estudante em cada conceito do domínio a ser aprendido. Taxonomia de Bloom é uma estrutura que organiza os objetivos educacionais para avaliação de

desempenho e desenvolvimento de competências de estudantes, baseados em três domínios: cognitivo, afetivo e psicomotor (BLOOM; COLLEGE; EXAMINERS, 1964).

Para alcançar os objetivos de modelagem, Dorça et al. (2012) considera os objetivos de aprendizagem, nível cognitivo e EA dos estudantes. Neste contexto, a Taxonomia de Bloom é utilizada para medição do nível de conhecimento do estudante, onde cada conceito do domínio a ser aprendido é armazenado e atualizado durante o processo de aprendizagem.

A definição do ME proposta por Dorça et al. (2012) utiliza o EA, o estado cognitivo (EC) e os objetivos de aprendizagem (OA) que são gerados através do seu conceito e valor, ao longo a utilização do sistema. O OA indica qual valor de nível cognitivo que o estudante precisa atingir para aprender determinado conceito de domínio. O nível cognitivo atualizado do estudante no conceito pretendido é indicado pelo EC. O processo é finalizado quando os OA forem atingidos, de modo que o EC seja igual ao OA.

2.5 ESTILO DE APRENDIZAGEM

Atualmente muitos estudos são realizados a cerca dos estilos de aprendizagem que são as maneiras que uma pessoa utiliza para conseguir aprender o que lhe é ensinado. Cada indivíduo reúne formas preferenciais de assimilar melhor um determinado conhecimento. Da mesma forma, existem muitos autores (Kolb, Dunn, Felder-Silverman, Garcia, Keefe-Jenkind, entre outros), que discutem e propõem conceitos e modelos sobre Estilos de Aprendizagem e suas principais características.

A aprendizagem tem sido considerada um processo ativo direcionado para o indivíduo e não um processo passivo voltado para uma massa. Com isso, o aluno contextualiza internamente o conhecimento, que resultam numa interpretação individual da sua vivência.

A diferença encontrada entre alunos durante o processo de aprendizagem e nos resultados alcançados em pesquisas, conduziu à crença na existência de diferentes estilos de aprendizagem que influenciam no aprendizado e de como cada indivíduo recebe e compreende as informações de forma a transformá-la em conhecimento (KOLB, 1984).

De acordo com Logan e Keefe (1997), os estilos de aprendizagem são as preferências da forma como as pessoas recebem e processam as informações sendo considerada uma habilidade, e dessa forma são passíveis de serem desenvolvidas. Porém, alguns aprendizes tendem a ter mais atenção em dados e programas, outros conseguem aprender mais a partir de mediações verbais ora orais ou escritas.

Já Schmeck (1982) define EA como uma predisposição do aluno em criar suas próprias estratégias para aprender, independente de como seja a tarefa. Regularmente os aprendizes adotam maneiras particulares e autônomas para lidar com situações de

aprendizagem.

De acordo com [Keefe e Jenkins \(2013\)](#) a questão que envolve os EA vai além das características pessoais e envolve também o ambiente onde o estudante vive. Características fisiológicas, afetivas e cognitivas estabilizam a forma de aprender e de reagir dentro de um ambiente de aprendizagem.

Segundo [Felder e Henriques \(1995a\)](#) acredita que existem aqueles que preferem aprender por mídias visuais como figuras e desenhos esquemáticos, onde outras pessoas entendem melhor com modelos matemáticos e teorias. Existem ainda os que preferem aprender as informações de forma interativa e participativa, já outros indivíduos possuem características individuais e internalizadas para adquirir conhecimentos.

[Kolb \(1984\)](#), ressalta que a aprendizagem ocorre com a aquisição da informação ou experiência, que interage com o repertório interno do indivíduo e as informações são adaptadas conforme a necessidade ou interesse dos alunos. O processo de aprendizagem se modifica dependendo da interpretação e formulação da experiência individual, gerando a construção do conhecimento.

Os autores [Berings, Poell e Simons \(2005\)](#) definem como Estratégias de Aprendizagem a atividade que o aprendiz realiza de combinar habilidades de aprendizagem de acordo com seu gosto. Dependendo da necessidade o estudante faz usos de tais combinações para facilitar o entendimento do conteúdo.

Existem diversos estudos sobre Estilos de Aprendizagem com várias teorias, propostas e modelos estudados por vários autores, como Modelo de Aprendizagem [Kolb \(1984\)](#), Variáveis Ambientais, Emocionais, Sociais e Psicológicos no Aprendizado [Dunn et al. \(1979\)](#), Recepção, Reação e Resposta à Aprendizagem [Logan e Keefe \(1997\)](#), entre outros.

Todos os conceitos expostos nessa seção, independente do autor ou teoria, convergem para qual é a melhor forma de um aprendiz assimilar seus conceitos. Na próxima seção será apresentado um modelo estruturado de utilização sistemática de EA e suas aplicações onde serviu de base para a presente pesquisa.

2.6 MODELO DE ESTILO DE APRENDIZAGEM FELDER-SILVERMAN

Os autores Richard Felder e Linda Silverman publicaram em 1988 sua pesquisa sobre Estilos de Aprendizagem. Segundo eles, a aprendizagem depende da preparação educacional do aprendiz e a conexão dos seus EA com o estilo de ensino do professor ([FELDER; SILVERMAN et al., 1988](#)).

A maior contribuição de Felder & Silverman para os estudos sobre estilo de aprendizagem foi a criação de um modelo que explica como um aprendiz se comporta e

se relaciona diante da oferta de informação. Baseados em estudos de Kolb (1984), que se aprofunda na aprendizagem experimental e em estudos de Jung (1971), que descreve como as funções psicológicas reconhecem e se orientam com o mundo externo, foi criado o Modelo de Estilo de Aprendizagem Felder-Silverman (FELDER; HENRIQUES, 1995b).

Soloman e Felder (1999) elaboraram o Index of Learning Style Questionary (ILSQ). Este consiste de um questionário psicométrico composto por onze perguntas para cada dimensão, somando ao total quarenta e quatro perguntas. O ILSQ tem objetivo de oferecer dados para definição das tendências de um estudante para cada dimensão e assim inicializar o Modelo do Estudante.

Inicialmente, o Modelo de Estilo de Aprendizagem Felder-Silverman (FSLSM) era composto por cinco dimensões de Estilos de Aprendizagem. Cada dimensão possuía dois estilos de aprendizagem que correspondiam às preferências que um aprendiz possui para aprender um conhecimento: percepção (sensorial e intuitivo), retenção (visual e auditivo), organização (indutivo e dedutivo), processamento (ativo e reflexivo) e compreensão (sequencial e global) (FELDER, 1988). No entanto, Felder e Henriques (1995b) redistribuem os estilos de aprendizagem reduzindo para quatro as dimensões, conforme a tabela 1:

Tabela 1 – Modelo de Estilo de Aprendizagem Felder-Silverman

Processamento		Percepção		Entrada		Organização	
Ativo	Reflexivo	Sensorial	Intuitivo	Visual	Verbal	Sequencial	Global

Felder e Henriques (1995b) publicaram o trabalho onde concluíram que o processo de aprendizado possui duas etapas: a recepção e processamento de informações. A proposta do seu modelo é identificar duas formas antagônicas para os meios de como os aprendizes preferem receber e processar as informações:

- Processamento (Ativo e Reflexivo): indica como as informações são percebidas e convertidas em conhecimento. Os ativos preferem experimentar e participar de forma coletiva. Os reflexivos primam pela reflexão e trabalham individualmente;
- Percepção (Sensorial e Intuitivo): como as pessoas percebem o ambiente ao seu redor. Os sensoriais preferem fatos e dados, dando valor a experiências. Os intuitivos são menos atentos e preferem princípios teóricos;
- Entrada (Visual e Verbal): forma como preferem receber o conhecimento. Os visuais têm boa memória gravando figuras, desenhos, filmes, esquemas experiências práticas. Os verbais preferem receber as informações ditas, escritas ou cantadas;
- Organização (Sequencial e Global): relacionada com a forma que se acompanha um assunto. Os sequenciais aprendem melhor quando o material é apresentado de forma

lógica, cronológica e sistemática. Os globais preferem escolher qual a sequência que vai aprender, sem respeitar cronologia ou ordem lógica.

Uma observação importante sobre a aplicação deste modelo é que o FSLSM é baseado em uma experiência comprovada baseado em respostas da aplicação do ILSQ, em amostras de diversas turmas de engenharia (FELDER; SILVERMAN et al., 1988). Esse trabalho pôs a prova a coerência entre as dimensões e seus EA vinculados.

Uma característica importante do FSLSM é que os estudantes podem apresentar variações de EA dentro de cada dimensão. De acordo com Dorça et al. (2012), as dimensões do modelo são dinâmicas, oferecendo ao estudante a oportunidade de evoluir ou adaptar a tendências de aprendizagens diferentes.

O FSLSM é um dos modelos mais utilizados para a implementação sistemática de modelos matemáticos aliados a métodos probabilísticos. Al-Azawei e Badii (2014) descrevem em seu trabalho que a aplicação de Cadeia de Markov, Modelo Oculto de Markov, Redes Bayesianas, entre outras técnicas de probabilidade, traz aos modelos que utilizam o FSLSM uma grande robustez nos processos e confiabilidade nos resultados.

Assim sendo, dados os conceitos apresentados referente aos EA, a seção seguinte apresenta diferentes técnicas para detectar o Estilo de Aprendizagem do estudante a fim de adaptar o sistema a estes estilos.

2.7 DETECÇÃO DE ESTILO DE APRENDIZAGEM

A popularização da EaD implica em uma oferta generalizada de cursos onde um único conteúdo é oferecido para um grande número de estudantes. Todos os participantes de um único curso utilizam exatamente o mesmo material didático para desenvolver suas atividades educacionais de aprendizagem, não levando em consideração as preferências de aprendizado individual do estudante. Dessa forma se faz necessário um sistema de detecção automática dos estilos de aprendizagem dos participantes nos cursos em AVA, para que seja oferecido formas mais adaptadas de conteúdo para facilitar o aprendizado.

Os estudantes aprendem de muitas maneiras diferentes: por ver e ouvir; refletir e agir; raciocinar logicamente e intuitivamente; memorização e visualização; analogias e construção de modelos matemáticos; de forma constante e não sequencial. O ensino e métodos também devem variar. Uma relação é estabelecida entre ensino/aprendizagem: a maior aprendizagem pode ocorrer quando o estilo de ensino corresponde aos estilos de aprendizagem do estudante (PUGA; GARCÍA, 2008).

Atualmente existem autores como Dorça et al. (2012), Sena et al. (2016), García et al. (2007), Puga e García (2008), Silva e Dorça (2014), entre outros, que dedicam pesquisas para desenvolver métodos de detecção automática de estilos de aprendizagem de estudantes.

Dorça (2004) afirma que é ineficaz a utilização de técnicas estáticas para detecção de estilos de aprendizagem, pois a tentativa de se detectar algum estilo de aprendizagem do estudante, na maioria dos ambientes virtuais de aprendizagem, é aplicada normalmente quando o estudante se cadastra no sistema.

Segundo Silva e Dorça (2014), a eficiência na detecção automática de Estilos de Aprendizagem de estudantes de AVA, utilizando modelos não determinísticos ao invés de modelos determinísticos, apresenta resultados com alto nível de precisão e baixo custo computacional, principalmente se comparada a outras abordagens analisadas que utilizam regras complexas.

De acordo com Felder e Spurlin (2005), a detecção automática de estilos de aprendizagem substitui a utilização de questionários psicométricos para inicializar o Modelo do Estudante nos SAIE tornando a detecção mais precisa pois utiliza dados históricos ao invés de preenchimento de questões em um tempo definido.

Uma das mais desejadas características de um sistema de ensino baseado na Web é a de ser adaptável e personalizado, uma vez que ele tem que ser usado por uma grande variedade de estudantes com diferentes habilidades e estilos de aprendizagem. Para isso, é necessário reduzir a distância entre o estilo de aprendizagem do estudante e o estilo de ensino, adaptando o curso às necessidades do estudante (López Puga et al., 2007).

Lugo, Rodr e Garc (2015) afirmam que uma ferramenta que apresente material educativo ao estudante de forma adequada em ambientes de aprendizagem personalizados passa pela implementação de um mecanismo de detecção automática de estilos de aprendizagem. Nestes sistemas os estudantes são caracterizados em um mecanismo que adapta a instrução educacional ao seu estilo de aprendizagem.

Um dos desafios em pesquisa é encontrar formas de coletar os dados que caracterizam a classificação do estilo de aprendizagem de um estudante, viabilizando o modelo do estudante. Nos últimos anos muitos pesquisadores utilizaram técnicas heurísticas para construir o modelo do estudante de forma automática. Alguns trabalhos de autores relacionados com a detecção do Estilo de Aprendizagem de Estudantes utilizam Redes Bayesianas Puga e García (2008), Modelo Oculto de Markov Sena et al. (2016), Cadeia de Markov Dorça et al. (2012), Lógica de Fuzzy Rodrigues et al. (2016), entre outros.

García et al. (2007) escreve sobre um procedimento que utiliza Rede Bayesiana para detectar os Estilos de Aprendizagem baseado no modelo FSLSM e os fatores que determinam cada uma dessas dimensões. Em seu trabalho, García et al. (2007) utiliza dados de um Ambiente Virtual de Aprendizagem de um curso de engenharia.

García et al. (2007) adota uma abordagem de engenharia de conhecimento para alimentar a Rede Bayesiana que detecta o Estilo de Aprendizagem dos estudantes baseado no FSLSM, onde considera apenas três dimensões do quadro FSLSM de 1988, que continha

na época cinco dimensões. Porém, Garcia utiliza somente três que são a percepção, processamento e compreensão. A dimensão de entrada foi descartada porque não foi considerado materiais de vídeos ou simulações como parte dos cursos Web. Foi também descartado a dimensão organização porque foi demonstrado que a maioria dos estudantes de engenharia são indutivos (FELDER, 1988).

Em sua pesquisa, [García et al. \(2007\)](#) analisa fatores para determinar o Estilo de Aprendizagem dos estudantes utilizando informações que são obtidas através da análise dos dados gravados em um arquivo de *log* de estudante. Para cada dimensão, são consideradas as seguintes variáveis:

- Dimensão Percepção: se os estudantes revisam os exames e quanto tempo esta revisão leva; quanto tempo o estudante leva para terminar um exame e entregá-lo; a quantidade de vezes que o estudante muda suas respostas em um exame; o tipo de material de leitura que o estudante prefere (concreto ou abstrato); o número de exemplos de um dado tema que o estudante lê; o número de exercícios que um estudante faz sobre um determinado tópico;
- Dimensão Processamento: Para detectar se o estudante prefere resolver as coisas sozinho, de forma reflexiva ou em grupos, de forma ativa, foi analisada a participação em fóruns, *chats*, e sistemas de e-mail;
- Dimensão Compreensão: análise dos padrões de acesso à informação, os quais são registrados nos arquivos de registro dos estudantes. Se o estudante salta através dos conteúdos do curso, pode-se dizer que ele não aprende sequencialmente, mas de forma não-sequencial.

Outro trabalho relacionado com detecção de EA foi descrito por [Amir et al. \(2016\)](#), que utiliza o método de Máquina de Vetor de Suporte (SVM). Trata de um sistema de aprendizagem que usa uma forma hipotética de relações entre espaço de função linear e espaço de recurso de alta dimensão. Uma SVM é um classificador linear, que reconhece padrões e realizando a transformação dos dados no espaço de entrada em espaço dimensional em um novo espaço vetorial para detecção de EA baseado no FSLSM.

[Amir et al. \(2016\)](#) relata em seu trabalho que os dados dos estudantes foram extraídos de *logs* de aprendizado em um sistema de gerenciamento chamado Ambiente de *e-Learning* do Estudante. Os dados utilizados neste estudo são dados de registro de aprendizagem da Faculdade de Ciência da Computação da Universidade da Indonésia.

Os dados são consolidados e pré-processados com o objetivo de obter o rótulo de dados usando o processo de classificação SVM. Durante o pré-processamento de dados, são realizadas as seguintes etapas:

- Definição dos padrões de comportamento de aprendizagem que são relevantes para o estilo de aprendizagem, comparando características de estilos de gerenciamento de aprendizagem pelo Moodle. Em seguida, determina o padrão de comportamento de aprendizagem do recurso e mapeia com base no FSLSM os recursos que correspondem ao estilo de aprendizagem ativo e reflexivo;
- Determina o limiar dos padrões de comportamento de aprendizagem, os recursos e o padrão de comportamento de aprendizagem que foi encontrado a partir dos resultados anteriores;
- Define o EA em um processo de rotulagem calculando o número de acesso de qualquer padrão de comportamento que tenha sido definido com base no ID do usuário, calculando o total dos recursos relevantes para cada estilo de aprendizagem e dividido pelo número envolvido.

O experimento foi realizado cinco vezes com a validação cruzada onde 200 dados são divididos em 5 partes em que 4/5 dos dados são tratados como dados de treinamento e os outros 1/5 como dados de teste. A composição dos dados de treinamento e dados de teste foram selecionados aleatoriamente utilizando uma técnica de retenção.

O terceiro trabalho relacionado a detecção automática de EA é de (SENA *et al.*, 2016). Em sua pesquisa, o autor utiliza técnicas de inferência probabilística dos modelos ocultos de Markov (HMM). Sena *et al.* (2016) faz a validação do modelo realizando experimentos em um simulador computacional. Este simulador é capaz de reproduzir parcialmente o processo de interação do estudante com o ambiente virtual de aprendizagem, utilizando o algoritmo de Viterbi, realizando um processo de inferência com base no comportamento do estudante.

Sena *et al.* (2016) também utiliza o modelo FSLSM para classificar e identificar os EA dos estudantes. O modelo oculto de Markov utiliza variações das cadeias de Markov, que consideram as distribuições de probabilidades somadas às observações e comportamentos do ambiente em que foi inserido. O modelo contempla um processo duplamente estocástico, onde um processo oculto não observável recebe dados sequenciais de um outro processo que monitora o comportamento do ambiente.

Para construir e formalizar o HMM em sua pesquisa, Sena *et al.* (2016) utiliza marcadores de características específicas das dimensões e EA do FSLSM. Essas características são atribuídas e quantificadas para alimentar o HMM, que processa os dados de todas as dimensões e seus EA.

Com o resultado do processo probabilístico do HMM, Sena *et al.* (2016) inicializa o algoritmo de Viterbi para promover o processo decisório e identificar qual o EA do estudante.

O último trabalho relacionado citado é o de [Rodrigues et al. \(2016\)](#), que utiliza técnicas de Lógica *Fuzzy* para implementar um algoritmo que detecta automaticamente os EA dos estudantes.

Em seu trabalho, [Rodrigues et al. \(2016\)](#) utiliza um Sistema Adaptativo e Inteligente para Educação proposto por [Dorça et al. \(2012\)](#) e simulação computacional para gerar o comportamento do estudante, onde aplica a lógica de *Fuzzy*, fazendo uso da teoria de conjuntos. Esta técnica apresenta facilidade de se adaptar a situações onde não há uma definição única ou binária de determinadas características.

Para desenvolver o modelo de detecção de EA, [Rodrigues et al. \(2016\)](#) se baseia também no FSLSM.

O sistema utiliza um algoritmo para ajustar os parâmetros de seleção das combinações de estilos de aprendizagem utilizando um histórico de notas do estudante, definindo um Conjunto Universo, um Conjunto Difuso e o Grau de Pertinência. Em seguida é determinada uma relação entre o conjunto difuso e o grau de pertinência que varia entre 0 e 1 ([RODRIGUES et al., 2016](#)).

[Rodrigues et al. \(2016\)](#) faz uma relação entre as médias das notas boas e ruins para que seja aplicada às Regras de Defuzzificação definidas abaixo .

- Definir um peso para cada Conjunto Difuso de forma que Estilos de Aprendizagem com menor média em notas ruins e maior média em notas boas tenham maiores probabilidades de serem selecionadas.
- Para cada dimensão do modelo, verificar o estilo de aprendizagem com menor média nos conjuntos difusos Muito Ruim e Ruim e maior média para os conjuntos difusos Média, Boa, Muito Boa.
- Atribuir uma recompensa para cada um desses conjuntos difusos que reflita a sua importância durante o processo de seleção de CEA.

Considerando as relações dos resultados da aplicação das Regras de Defuzzificação, o sistema consegue determinar qual é o EA do estudante em cada dimensão do FSLSM.

3 Referencial Teórico

Neste capítulo será apresentado as técnicas e fundamentos que serviram de base para a estruturação e construção da proposta do presente trabalho. A seção 3.1 aborda a importância das inferências probabilísticas como suporte às técnicas de aprendizado de máquina para representar as crenças de um agente. A seção 3.2 discute aplicação de metaheurística bayesiana no campo da inteligência artificial. A seção 3.3 conceitua Redes Bayesianas e suas particularidades aplicadas na modelagem probabilística de causa e efeito. A seção 3.4 apresenta características importantes da Aprendizagem por Reforço. Finalizando este capítulo, a seção 3.5 aborda características sobre Sistemas Adaptativos e Inteligentes para Educação.

3.1 INFERÊNCIAS PROBABILÍSTICAS

As inferências probabilísticas são largamente utilizadas para compor modelos de aprendizagem de Máquina com a finalidade de detectar e prever variáveis desconhecidas em ambientes em situações que envolvem incertezas. A probabilidade é descrita por [Russell e Norvig \(2004\)](#) como uma forma de representar as crenças de um agente, ao invés de ter um significado físico externo.

As inferências probabilísticas, de acordo com [Correia \(2003\)](#), podem ser classificadas como determinísticas e não determinísticas. Os fenômenos determinísticos ocorrem em ambientes com um alto grau de precisão entre os resultados. Os fenômenos não determinísticos são aqueles que possuem um alto grau de incerteza, produzindo resultados distintos mesmo observando as condições idênticas.

[Martins \(2005\)](#) define o processo de inferência usando probabilidades como a ação que resulta na observação de um fenômeno aleatório. Do fenômeno aleatório obtém-se um resultado que possivelmente pode ser previsto com antecedência, mas não existe conhecimento suficiente para que uma experiência realizada repetidas vezes possa ter resultados previsíveis. Isso demonstra relações de independência entre os resultados probabilísticos.

Segundo [Gardiner \(1983\)](#) todo processo probabilístico onde o resultado não é possível de se prever de maneira antecipada é considerado aleatório, não-determinístico ou estocástico. Um mesmo procedimento estocástico pode ser repetido diversas vezes obtendo resultados duvidosos, porém ao longo das repetições, obtém-se resultados com maior regularidade e segurança.

3.2 METAHEURÍSTICA BAYESIANA

Metaheurísticas são estruturas lógicas algorítmicas genéricas adaptáveis a diversos problemas. As metaheurísticas podem ser concebidas como estratégias gerais para a concepção de procedimentos com alto desempenho. As metaheurísticas são utilizadas para pesquisa que constituem um paradigma central de técnicas na solução de problemas de otimização (MELOROSE; PERROY; CAREAS, 2015).

A ideia mais genérica do termo metaheurística está relacionada com a tarefa de resolver problemas reais de forma inteligente usando o conhecimento disponível, (MELIÁN; Moreno Perez; Marcos Moreno-Vega, 2003). Redes Bayesianas, também conhecida como Teoria da Crença, surgiu como um método probabilístico que permite a representação eficiente do conhecimento para previsão ou entendimento de um certo estado.

Segundo Melorose, Perroy e Careas (2015), as teorias Bayesianas são largamente utilizadas no campo da Inteligência Artificial para tratamento de incertezas e apoio à tomada de decisão sistêmicas. Redes Bayesianas constituem um modelo gráfico que representa de forma simples as relações de causalidade das variáveis de um sistema. Como consequência, o modelo de rede Bayesiana é utilizado para medir o risco operacional, identificar a influência dos fatores de risco, calcular a sensibilidade nos eventos de perda e detectar padrões e tendências (MARQUES; DUTRA, 2002).

Para Russell e Norvig (2004), Metaheurísticas Bayesianas são muito utilizadas em problemas que envolvem incerteza, pois permitem inferir atribuições probabilísticas anteriores à proposição inicial. Tais variáveis podem representar crenças pré-definidas incidindo na atualização do próprio modelo bayesiano à medida que vão alcançando as evidências, permitindo que probabilidades desconhecidas sejam calculadas a partir de probabilidades condicionais conhecidas em um sentido causal.

A modelagem bayesiana permite a inclusão de dados subjetivos de especialistas, no caso de insuficiência de informações passadas. Além disso, tal modelagem permite a medição de forma sistemática da ocorrência de fatores de risco que possam levar a eventos de baixa frequência e alta severidade. Como consequência, tais modelos são utilizados para medir o risco operacional, identificar a influência dos fatores de risco, calcular a sensibilidade nos eventos de perda e simular a distribuição de perdas e cenários de perda excessiva (MARQUES; DUTRA, 2002).

3.3 REDES BAYESIANAS

As Redes Bayesianas (RBs) também chamadas de Rede de Crenças, empregam a teoria de grafos e a teoria de probabilidades para modelar relações de causa e efeito entre variáveis aleatórias. As variáveis são representadas por vértices e suas relações são

representadas por arestas direcionadas. Cada vértice possui um conjunto de estados finitos mutuamente exclusivos e há influência de cada estado de uma variável sobre a outra.

RB é uma estrutura probabilística, capaz de utilizar dados com um alto grau de incerteza, capaz de utilizar dados em situações não determinísticas, com o poder de representar modelos onde existem crenças que algum estado pode ocorrer (WOODBERRY et al., 2004).

As RBs constituem um modelo gráfico que representa as relações probabilísticas entre as variáveis de um sistema. Tais redes são sempre representadas por um conjunto de vértices (V) e um conjunto de arestas. Cada vértice representa uma determinada variável aleatória e cada variável deve ter um número finito de estados, como Verdadeiro e Falso. Cada aresta representa uma relação causal entre as variáveis, sendo que a aresta é direcionada da causa para o efeito com o símbolo de uma seta (HAMMOND; O'BRIEN, 2001).

Um dos conceitos mais utilizados foi descrito por Jensen (1996), que em seu livro diz que uma RB é a representação compacta e expressiva de relações incertas entre parâmetros em um domínio, formado por um grafo acíclico dirigido onde os nós representam variáveis aleatórias e os arcos representam as correlações probabilísticas entre as variáveis.

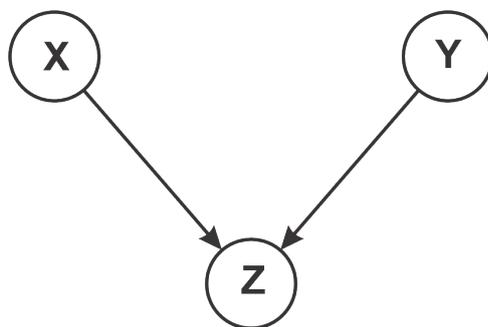


Figura 2 – Grafo bayesiano das relações condicionais entre variáveis

Nagarajan, Scutari e Lèbre (2013) diz que RB é um modelo gráfico que permite a representação clara e precisa das dependências probabilísticas entre variáveis aleatórias $X = X_1, X_2, \dots, X_n$ em um formato de Grafo Dirigido Acíclico (DAG) onde cada arco está associado a um par de vértices e a seus pontos finais, conforme mostra a Figura 2.

Segundo Russell e Norvig (2004), as RBs são largamente utilizadas no campo da Inteligência Artificial para tratamento de incertezas e apoio às tomadas de decisão sistêmicas. A aplicação de RB atribuiu um grau de crença entre 0 e 1 a cada possibilidade, permitindo que os agentes lidem com um alto grau de incerteza, analisando as evidências das probabilidades, possibilitando realizar diversos tipos de consultas.

A teoria da Independência Condicional trata das relações de independência entre variáveis, onde os eventos são independentes quando a ocorrência de um não influencia na

ocorrência do outro (BELLOT, 2016). De acordo com Russell e Norvig (2004), os requisitos para levantamento das variáveis são evidências separadas: a probabilidade causal para a variável de consulta e a probabilidade condicional de efeito, dada as probabilidades de suas causas conforme a equação 3.1.

A notação generalizada de independência condicional entre duas variáveis X e Y , dada uma terceira variável Z é:

$$P(X, Y|Z) = P(X|Z)P(Y|Z) \quad (3.1)$$

Para classificar e organizar todos valores de Probabilidade Condicional, use-se uma estrutura conhecida como Tabela de Probabilidade Condicional (TPC) que é um termo para designar a representação da memória de distribuição das probabilidades (BELLOT, 2016). Na Teoria de Probabilidade Condicional pode-se armazenar variáveis contínuas ou discretas que mostram as relações condicionais entre os nós da aplicação bayesiana. Cada linha da TPC contém a PC de cada valor do nó de um grafo para um caso de condicionamento (RUSSELL; NORVIG, 2004).

São utilizadas na representação do conhecimento de domínio por meio de relações das dependências entre variáveis aleatórias, pelas probabilidades condicionais entre variáveis e pelos conjuntos de probabilidades *a priori* (NEUFELD, 1993). Como consequência, o modelo de RB é utilizado para medir o risco operacional, identificar a influência dos fatores de risco, calcular a sensibilidade nos eventos de perda e detectar padrões e tendências utilizando o conceito de Probabilidade Condicional (MARQUES; DUTRA, 2002).

De acordo com Horny (2014), Probabilidade Condicional (PC) se refere às possibilidades de um evento acontecer, condicionado a um ou mais outros eventos, onde os eventos são possíveis de ocorrer, ou seja, pertencerem a um conjunto não vazio de um espaço amostral. Bellot (2016) descreve a PC como sendo a qualificação da relação causal de variáveis que levam a um dado evento probabilístico.

Baseado nas premissas de causa e evidência da Teoria da Probabilidade Condicional, define-se a seguinte observação em 3.2:

$$P(\text{causa}|\text{evidência}) = \frac{P(\text{causa} \cap \text{evidência})}{P(\text{evidência})} \quad (3.2)$$

Da mesma forma, quando observado o seu inverso em 3.3:

$$P(\text{evidência}|\text{causa}) = \frac{P(\text{causa} \cap \text{evidência})}{P(\text{causa})} \quad (3.3)$$

Observando a Teoria da Multiplicação, obtém-se a equação 3.4:

$$P(\text{causa} \cap \text{evidência}) = P(\text{causa})P(\text{evidência}|\text{causa}) \quad (3.4)$$

Para obter o Teorema de Bayes, é necessário aplicar o Teorema da Probabilidade Total 3.5

$$P(\text{evidência}) = \sum_{i=1}^n P(\text{causa}_i)P(\text{evidência}|\text{causa}_i) \quad (3.5)$$

Com a proposta de substituição dos termos obtém-se a Teoria de Bayes na equação 3.6:

$$P(\text{causa}|\text{evidência}) = \frac{P(\text{evidência}|\text{causa})P(\text{causa})}{P(\text{evidência})} \quad (3.6)$$

O cálculo da probabilidade de uma Rede Bayesiana é dado pelo Teorema de Bayes que segue abaixo na equação 3.7:

$$P(Y|X) = \frac{P(X|Y)P(Y)}{P(X)} \quad (3.7)$$

A fórmula representa o funcionamento da Regra de Bayes onde, a variável X representa as probabilidades *à priori*, sendo valores já conhecidos, responsáveis pelas causas de um resultado. A variável Y representa as probabilidades dos valores *à posteriori*, responsáveis pelos efeitos de um resultado. Tal resultado é dividido pelo $P(X)$ que representa a Probabilidade Total (PT) das variáveis conhecidas. O cálculo da Probabilidade Total é dado pela seguinte fórmula na equação 3.8:

$$PT = P(X|Y)P(X) + P(Y|X)P(Y) \quad (3.8)$$

Horny (2014) reforça as relações probabilísticas causais entre as variáveis aleatórias de uma RB com suas dependências condicionais, determinando uma representação da distribuição das probabilidades em um DAG. O real objetivo de uma RB é calcular a probabilidade condicional de todas as possibilidades causais não observadas, dada a evidência observada, ou ao contrário, sendo $P(\text{Causa} | \text{Evidência})$ ou $P(\text{Evidência} | \text{Causa})$.

RBs têm sido utilizadas em diversos campos do conhecimento que envolvam incerteza e necessidade de auxílio para tomada de decisão. Estas áreas de conhecimento passam por: diagnóstico médico, mapas de aprendizado, entendimento de linguagem, visão, busca heurística, entre muitos outros (CHARNIAK, 1991).

Piombo, Batatia e Ayache (2003) utiliza RB em seu trabalho, associada ao modelo FSLSM, para criar um modelo computacional para detectar automaticamente os EA dos estudantes em AVA. Ainda segundo o autor, RB são mais indicadas para esse fim pois torna possível a representação das incertezas de um estudante, graças a sua rigorosa dinâmica probabilística.

Os modelos probabilísticos Bayesianos apresentam-se como alternativas para contornar os problemas normalmente encontrados na medição de riscos operacionais, uma vez que é comum a insuficiência de dados e, normalmente quando existem, são dados históricos. As RBs podem ser utilizadas para tomar decisões baseadas em probabilidades, decidir quais evidências adicionais devem ser observadas a fim de se obter informações úteis do sistema e analisar o sistema a fim de buscar os aspectos do modelo que possuam maior impacto sob as variáveis de consulta (MARQUES; DUTRA, 2002).

Em relação a outros modelos probabilísticos disponíveis, as Redes Bayesianas apresentam vantagens por serem facilmente compreendidas, dado que as relações entre as variáveis são, em grande parte, intuitivas. Outra vantagem é que este modelo provê informações sobre o efeito de possíveis intervenções nas variáveis da rede, bem como demanda menor tempo computacional de solução, uma vez que normalmente os algoritmos de Redes Bayesianas são menos complexos que outros modelos probabilísticos.

Contudo, as Redes Bayesianas se fundamentam em distribuições de probabilidade que, embora não sejam conhecidas *a priori*, não mudam ao longo do tempo para as variáveis contempladas em um modelo. Outra consideração está relacionada ao nível de confiança de um resultado dado as condições das variáveis (AZOURY; MILLER, 1984).

Em seu livro, Russell e Norvig (2004) mostram os recursos e a capacidade das RBs em aplicações de modelos probabilísticos para resolução de problemas que envolvem um certo grau de incerteza, em situações que envolvem insuficiência de informações.

As RBs são consideradas como alternativas eficazes para determinar os EAs em AVA, utilizando padrões de comportamento entre os estudantes e as dimensões dos modelos de EA utilizados. Segundo Al-Azawei e Badii (2014) os problemas que envolvem variáveis não determinísticas apresentam uma modelagem computacional consideravelmente melhor quando aplicadas técnicas de RB.

Fundamentalmente, as RBs são usadas para atualizar probabilidades quando a informação chega. Para especificar a distribuição de probabilidades de uma Rede Bayesiana, é necessário obter as probabilidades de todos os nós-raiz (nós sem predecessores) e as probabilidades condicionais de todos os nós-não-raiz, dadas todas as possíveis combinações de seus predecessores diretos.

3.4 CADEIA DE MARKOV

Considera-se um processo aleatório ou estocástico o evento que não é possível afirmar com antecedência seu o resultado, mesmo que o processo seja repetido exatamente como o anterior, seu resultado pode ser diferente. Os eventos não-determinísticos possuem inicialmente a característica de serem pouco confiáveis. No entanto, após uma grande série de repetições, é possível identificar alguns padrões nos resultados (GARDINER, 1983).

De acordo com Atuncar (2011), um processo estocástico contempla uma família de variáveis aleatórias, comandadas por um processo de tempo discreto, onde o parâmetro t é finito e enumerável, ou de tempo contínuo onde o parâmetro não é possível de ser enumerado.

Monteiro (2006) define o processo estocástico como sendo uma evolução probabilística ao longo do tempo, sendo um fenômeno que apresenta variações imprevisíveis conforme o tempo passa. Uma Cadeia de Markov é um processo estocástico onde existe a independência condicional entre as variáveis de futuras com as variáveis já conhecidas (MEYN; TWEEDIE, 2012).

As Cadeias de Markov são largamente utilizadas para formalizar as transições entre estados onde as variáveis de controle possuem resultados estocásticos. O processo markoviano tem a propriedade de prever futuros estados em um sistema dinâmico, se baseando somente no estado presente, não levando em considerações os estados passados (DORÇA et al., 2012).

Com a aplicação da Cadeia de Markov é possível prever estados de um processo em andamento, baseando-se no estado atual e não na sua trajetória histórica, considerando um processo em que as variáveis sequenciais aleatórias assumem valores de um alfabeto finito, funcionando como uma máquina de estados onde as transições são estocásticas (CLARKE; DISNEY, 1979).

Conforme Meyn e Tweedie (2012), um processo de Markoviano estocástico com tempo e espaço de estados discretos, possuindo a propriedade dada pela equação 3.9

$$P(X_{n+1} = j | X_1, X_2, \dots, X_{n-1}, X_n) = P(X_{n+1} = j | X_n) \quad (3.9)$$

Desta forma, uma cadeia de Markov contempla as seguintes propriedades (PAPOULIS; PILLAI, 2002):

- Os resultados pertencem a um conjunto finito de estados $(x_1, x_2, x_3, \dots, x_k)$, onde são chamados de estados de sistema. Quando o estado resultante da $n - \text{ésima}$ tentativa é x_j , significa que o sistema se encontra no estado x_j , no momento n do processo.

- O resultado de um estado depende apenas do resultado do estado imediatamente anterior. A cada par de estados x_i, x_j está associada a probabilidade $P(x_j|x_i)$ de ocorrer x_j no instante n imediatamente após ter ocorrido x_i no instante $n - 1$, ou seja, $P(X_n = x_j|X_{n-1} = x_i)$.

Uma Cadeia de Markov é representada por um diagrama de transição ou autômato, representando os estados por círculos, e as probabilidades de transição entre esses estados, conforme a figura 4.

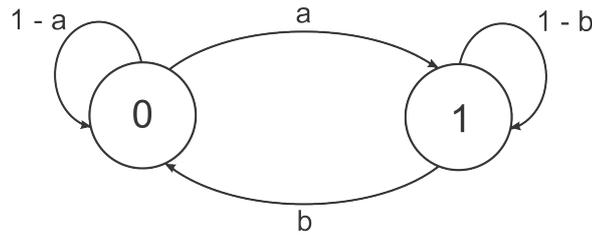


Figura 3 – Modelo de Cadeia de Markov

Outro elemento gráfico que representa a transição de probabilidades na cadeia de Markov é a matriz de transição que demonstra a transição dos estados na cadeia. Uma matriz que atenda a estas condições denomina-se matriz estocástica. A soma dos elementos em cada linha da matriz de transição deve ser igual a 1, representando as probabilidades do processo a partir de um estado atual, atingindo os demais estados. Ou seja, a probabilidade do estado atual representa a transição ou a permanência no estado tomado o valor complementar a 1 (MEYN; TWEEDIE, 2012). A matriz de transição de uma cadeia de Markov é uma matriz estocástica conforme a 3.10

$$\begin{pmatrix} 1 - a & a \\ b & 1 - b \end{pmatrix} \quad (3.10)$$

Uma Cadeia de Markov é considerada o contrário dos modelos determinísticos, onde só se conhece uma solução correta para a resolução de problemas em um universo específico de resultados. A maior vantagem dos modelos estocásticos está na convergência após diversas repetições com valores dos resultados de ampla variância, independente da complexidade do problema, proporcionando resultados não determinísticos de eventos do mundo real.

3.5 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma vertente da ciência que tem o objetivo de desenvolver dispositivos computacionais que simulem a capacidade raciocinar, perceber,

tomar decisões e resolver problemas como um ser humano, entendendo e construindo entidades e agentes inteligentes (RUSSELL; NORVIG, 2004).

Alan Turing desempenhou um importante papel para o surgimento da IA. Turing (1950) desenvolveu um teste para fornecer definições operacionais de inteligência de máquina. Tal teste ficou conhecido como Teste de Turing e tinha como objetivo principal verificar se as máquinas são capazes de pensar. Este pensamento pode ser definido como a capacidade de adaptação a circunstâncias novas e detecção de padrões por sistemas computacionais (RUSSELL; NORVIG, 2004).

Dentro dos padrões que conceituam a IA, a aprendizagem é a aquisição de novos conhecimentos para utilização em tarefas futuras no sistema, visando obter uma melhoria de desempenho em um sistema computacional (SHEREMETOV; MENTADO,). Iglesias et al. (2009), pontua a importância da aplicação de IA nos Sistemas Adaptativos e Inteligentes para Educação, tendo em vista o alto poder de gerar ambientes adaptáveis e inteligentes, capazes de promover o problema de heterogeneidade em cursos realizados na modalidade semipresencial ou à distância.

De acordo com Dorça et al. (2012) a introdução de técnicas de IA em programas de EaD eleva o ensino tradicional para um nível dinâmico e individualizado, oferecendo um ambiente computacional onde o ensino é personalizado e interativo. Os SAIE se adaptam não apenas às necessidades do usuário, mas aos conhecimentos, experiências, expectativas, preferências e características, sem a necessidade de cadastrar tais informações de maneira direta no sistema, fazendo uso de técnicas de Aprendizado de Máquina.

Aprendizado de Máquina (AM) é um segmento da IA que tem como finalidade desenvolver técnicas computacionais no campo do aprendizado, capazes de construir sistemas com o objetivo de adquirir conhecimento de forma automática (BREFELD; SCHEFFER, 2004). Um sistema baseado em AM é um programa de computador que utiliza dados históricos para tomar decisões com base em experiências passadas bem sucedidas.

Normalmente a AM é utilizada em análises de dados que envolvem larga escala. De uma forma histórica, suas pesquisas se inspiram em modelos biológicos para produção de modelos e algoritmos que possam resolver problemas, processando os dados como os sistemas orgânicos biológicos (BARBER, 2012).

Uma das grandes aplicações práticas de AM está na mineração de dados, que visa buscar, classificar, selecionar ou detectar padrões estruturais em dados para realizar previsões a partir dos seus resultados. Tais resultados fornecem uma representação clara do domínio conhecimento adquirido por um sistema (WITTEN et al., 2016).

De forma abrangente, a AM se divide em duas linhas de trabalho: a aprendizagem supervisionada e a não supervisionada.

A abordagem de AM supervisionada apresenta métodos de aprendizagem onde uma função é capaz de mapear corretamente um grande conjunto de dados de treinamento em classificações já observados, para posteriormente ser aplicada em um conjunto de dados não observados, na expectativa de se mapear e classificar corretamente tal conjunto. Partindo deste princípio, a função de AM supervisionada deve ser capaz de gerar uma generalização a partir de um conjunto de dados de treinamento (COPPIN, 2010).

Para Sanches (2003), na AM supervisionada o aprendizado se dá através de exemplos com valores rotulados pertencentes a uma classe, normalmente conhecidos como conjunto de treinamento. O conjunto de treinamento vai servir de parâmetro para um sistema gerar generalizações e especializações na indução de resultados classificadores.

Na abordagem de AM não supervisionada, também conhecida como Aprendizagem por Reforço, o agente desenvolve um aprendizado de forma autônoma para potencializar a sua performance dentro de um ambiente favorável e dinâmico (SUTTON; BARTO, 1998). O agente não recebe nenhuma supervisão externa para definir parâmetros ou padrões, ficando responsável por traçar suas próprias estratégias de otimização.

Aprendizagem por Reforço (AR) é uma aplicação de IA que permite a implementação de um agente com a capacidade de aprender com suas próprias experiências com o ambiente inserido. O sistema de aprendizagem é realizado quando realiza ações que mudam o seu estado (SUTTON; BARTO, 1998).

Segundo Russell e Norvig (2004) a tarefa da AR consiste em usar recompensas já observadas para aprender uma política de otimização para um determinado ambiente. Em problemas com alta complexidade, a AR é um modo de treinar um programa para obter desempenho de alto nível, em uma estrutura formada por estados, ações e recompensas.

De acordo com Serra (2004) um dos mais conhecidos e eficiente algoritmo de AR é o *Q-learning*, funcionando de forma interativa e autônoma, sendo um agente eficaz até mesmo em modelos implantados em ambientes precários

3.6 SISTEMAS ADAPTATIVOS E INTELIGENTES PARA EDUCAÇÃO (SAIE)

Segundo Dorça et al. (2012), existe uma variedade de fatores que influenciam na avaliação de aprendizagem, desempenho de estudantes e detecção de problemas de aprendizagem. A avaliação do estudante em AVA é um problema complexo, e uma série de abordagens têm sido propostas para resolvê-lo.

Neste contexto Dorça et al. (2012) propôs um modelo probabilístico que leva em consideração alguns estudos disponíveis na literatura sobre o impacto dos Estilos de Aprendizagem no desempenho do estudante, pois conhecendo os EA do estudante é

possível que um Sistema Adaptativo e Inteligente para Educação (SAIE) possa prover uma experiência que melhor se adapta aos EA do estudante. O processo que, segundo Dorça et al. (2012), reproduz esse cenário é o Processo Estocástico de Simulação de Desempenho do Estudante (PESDE).

O principal aspecto deste processo é que, quando um Estilo de Aprendizado real (EAR) é contemplado na Combinação dos Estilos de Aprendizagem (CEA) inferida pelo Modelo Pedagógico (MP), o aprendizado se torna mais fácil, e conseqüentemente a probabilidade de sucesso é maior (DORÇA et al., 2012). Em seu trabalho, Dorça et al. (2012) descreve CEA como sendo o conjunto das preferências de um estudante representadas por um Estilo de Aprendizagem das dimensões do modelo FSLSM, possibilitando 16 combinações diferentes.

O PESDE precisa conhecer não só os estilos de aprendizagem real do estudante, como também a força de cada preferência para desempenhar sua tarefa, pois essa força por uma preferência se mostrou um fator importante no desempenho dos estudantes segundo alguns autores. Dorça et al. (2012) observou em seus experimentos que estudantes com preferências muito fortes por um EA tiveram desempenho significativamente menor que alunos com preferências mais fracas quando elas não são satisfeitas pelo processo de ensino.

A definição do ME proposta por Dorça et al. (2012) utiliza o EA, o estado cognitivo (EC) e os objetivos de aprendizagem (OA) que são gerados através do seu conceito e valor, ao longo a utilização do sistema. O OA indica qual valor de nível cognitivo que o estudante precisa atingir para aprender determinado conceito de domínio. O nível cognitivo atualizado do estudante no conceito pretendido é indicado pelo EC. O processo é finalizado quando os OA forem atingidos, de modo que o EC seja igual ao OA.

Dorça et al. (2012) destaca que o PESDE calcula a quantidade de preferências não satisfeitas (Qpns) do estudante pela CEA selecionada. Caso uma das preferências não satisfeitas seja uma preferência forte, então o PESDE incrementa Qpns em 1. Caso não existam preferências fortes não satisfeitas, mas exista pelo menos uma preferência moderada não satisfeita então o PESDE incrementa Qpns em 0,5. Então, o cálculo da performance (PFM) do estudante é dado por $PFM = 100^{\sim}(Qpns \times K \times B)$; em que B é um número aleatório entre 0 e 1.

O resultado do cálculo de PFM do estudante compõem a probabilidade de um estudante preferir um EA dentro de uma dimensão do modelo FSLSM, chamado de Estilo de Aprendizagem Probabilístico (EAp). Isso possibilita representar as preferências do estudante através da distribuição das probabilidades por EA e o armazenamento direto dos EAp no Modelo do Estudante.

Dessa forma, o ME é atualizado frequentemente através do cálculo da PFM do estudante, melhorando e revisando as informações sobre os estilos de aprendizagem dos

estudantes durante o processo de aprendizagem. Conseqüentemente, essa atualização corrige dados inconsistentes no ME.

Após a inicialização e atualização do ME, a utilização desses dados passa a ser feita pelo Modelo Pedagógico (MP), que é responsável por selecionar a estratégia pedagógica mais adaptada a um estudante, tendo como base as observações armazenadas no Modelo do Estudante. O Modelo Pedagógico proposto por Dorça et al. (2012), tem como objetivo apresentar estratégias de ensino personalizada aos estudantes através de uma Combinação de Estilos de Aprendizagem, selecionados pelos resultados contidos no EAp.

Nesse sentido, a medida que são realizadas as sessões de aprendizagem, o MP atualiza o ME através de uma Cadeia de Markov, que atualiza os estados probabilísticos representados pelo EAp. A cadeia de Markov utiliza 4 variáveis probabilísticas independentes que representam as dimensões do modelo FSLSM, representando 4 máquinas de estados onde as atualizações desses estados são estocásticas. Este processo é responsável pela seleção de uma CEA durante as sessões de aprendizagem, atualizando com os EAp do estudante no ME.

Diante dessa observação, considera-se a possibilidade de um estudante possuir maior ou menor probabilidade de pertencer a uma das 16 CEAs. Com isso é possível categorizar pedagogicamente as preferências de um estudante (DORÇA et al., 2012).

Dorça et al. (2012) observou que quanto maior Qpns, pior o desempenho do estudante e destaca também que os valores das probabilidades de inferência utilizados pelo PESDE são razoáveis para uma experimentação confiável da abordagem proposta por ele. Desta forma, o modelo é capaz de inferir o desempenho e evolução de nível cognitivo do estudante de forma probabilística.

Dorça et al. (2012), em cada experimento, considerou estudantes de uma mesma categoria pedagógica específica, considerando as 16 possíveis CEAs. Desta forma, os Estilos de Aprendizagem reais do estudante são definidos em cada experimento. Assim, foi possível verificar o comportamento apresentado em diversos estudos, que atestam que atender os Estilos de Aprendizagem reais do estudante causa um impacto notoriamente positivo em seu desempenho.

Nos experimentos que validaram essa proposta foi considerado um conjunto de 60 conceitos a serem aprendidos por um estudante. O sistema atribui o estado cognitivo inicial do estudante o valor -1 em todos os conceitos. O sistema considera como objetivos de aprendizagem o nível máximo 5 de conhecimento nos conceitos.

O sistema finaliza quando o estudante atinge todos os objetivos de aprendizagem especificados no ME em todos os conceitos. Para tanto, o simulador executa o processo pelo menos 360 vezes para representar as sessões de aprendizagem ou iterações para atingir as metas de aprendizagem (60 conceitos x 6 níveis cognitivos em cada conceito = 360).

4 Metodologia

A abordagem proposta no presente trabalho foi verificada e validada utilizando a metodologia observada na seção 4.1, onde é explicado a proposta bayesiana para a composição do algoritmo, bem como a forma de funcionamento do mesmo. Para realizar o experimento sem precisar de coleta das informações de aprendizagem com estudante real, a abordagem faz uso de simulação computacional para emular o aprendizado de um estudante em Ambientes Virtuais de Aprendizagem para alimentar os processos probabilísticos.

4.1 ALGORITMO PROPOSTO

O presente trabalho propõem uma aplicação de Redes Bayesianas, com a finalidade de detectar qual o Estilo de Aprendizagem de um Estudante em Ambientes Virtuais de Aprendizagem, composto por um Sistema de Tutoria Inteligente.

Outros trabalhos relacionados com Detecção de Estilos de Aprendizagem utilizam informações obtidas através da análise dos dados gravados em arquivos de *log* de estudante. O presente algoritmo faz uso do Processo Estocástico de Simulação de Desempenho do Estudante (PESDE), desenvolvido por [Dorça et al. \(2012\)](#), onde não existe a presença de informações de estudantes reais.

O PESDE, por vez, retorna um conjunto de CEAs com suas respectivas notas, que serão utilizadas para alimentar a Tabela de Probabilidade Condicional que alimenta o Algoritmo de Rede Bayesiana.

4.1.1 PROPOSTA BAYESIANA

A presente proposta faz uso da técnica de Redes Bayesianas para atualizar o EA probabilístico no Modelo do Estudante, substituindo a abordagem de *Q-learning*, baseado em Aprendizagem por Reforço, proposto por ([DORÇA et al., 2012](#)). A expectativa é o algoritmo de RB seja equivalente ao comparado na literatura, porém mais rápido, confiável e eficiente.

O trabalho apresenta um modelo de Rede Bayesiana baseada no Modelo de Estilo de Aprendizagem Felder-Silverman (FSLSM), com suas respectivas Tabelas de Probabilidade Condicional, conforme a figura [4](#).

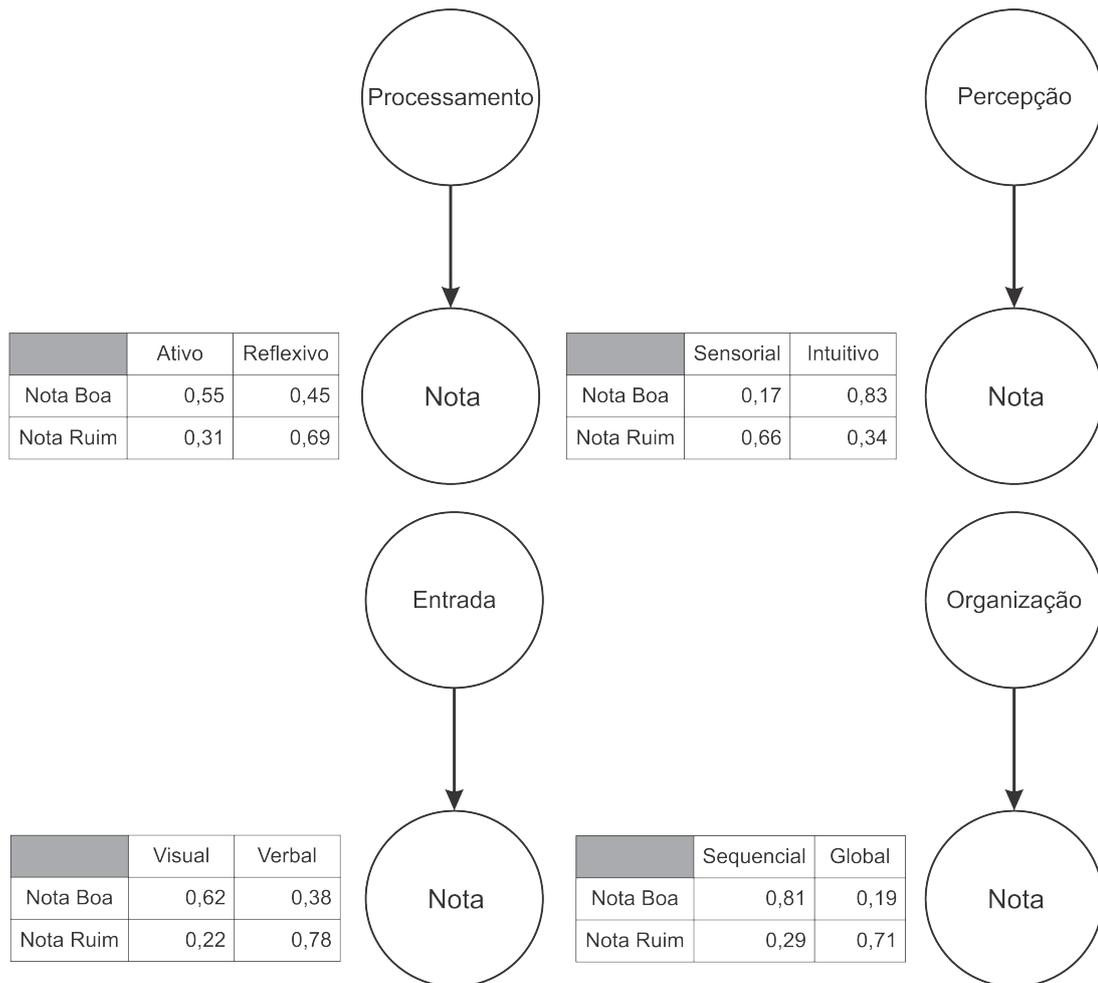


Figura 4 – Rede Bayesiana para de detecção do EA baseado no FSLSM

Para explicar o funcionamento do algoritmo, será considerado como exemplo somente a dimensão Processamento do FSLSM, que possui os Estilos de Aprendizagem Ativo e Reflexivo. Para simplificar a descrição do algoritmo, será utilizado uma Tabela de Probabilidade Condicional com somente dez registro de Estilos de Aprendizagem da dimensão Processamento e suas respectivas notas conforme exibidas na tabela 2

O algoritmo seleciona somente as notas satisfatórias, isto é, as notas acima de 60 e seus Estilos de Aprendizagem, desconsiderando as notas ruins.

Para a aplicação do Teorema de Bayes, é necessário extrair as variáveis probabilísticas, onde os valores conhecidos são: a probabilidade do Estilo de Aprendizagem ser Ativo - $P(ATI)$, e a probabilidade do Estilo de Aprendizagem ser Reflexivo - $P(REF)$.

Baseado nesse contexto e considerando somente as notas satisfatórias, pode-se observar a probabilidade da nota ser satisfatória , dada o Estilo de Aprendizagem ser Ativo e a probabilidade da nota ser satisfatória , dada o Estilo de Aprendizagem ser Reflexivo - $P(B|ATI)$, $P(B|REF)$.

Tabela 2 – Tabela de Simulação de notas com dez registros

Dimensão Processamento	Nota
Ativo	40
Ativo	42
Ativo	50
Ativo	30
Ativo	69
Reflexivo	31
Reflexivo	20
Reflexivo	70
Reflexivo	51
Reflexivo	79

Considerando os dados da Tabela 2, são gerados os valores probabilísticos da Rede Bayesiana, considerando as notas satisfatórias e não satisfatórias .

Probabilidade de notas satisfatórias:

$$P(B|ATI) = 1/5 = 0,2$$

$$P(B|REF) = 2/5 = 0,4$$

$$P(ATI) = 1/2 = 0,5$$

$$P(REF) = 1/2 = 0,5$$

Probabilidade de notas não satisfatórias:

$$P(R|ATI) = 4/5 = 0,8$$

$$P(R|REF) = 3/5 = 0,6$$

$$P(ATI) = 1/2 = 0,5$$

$$P(REF) = 1/2 = 0,5$$

O próximo procedimento do algoritmo é utilizar os valores probabilísticos da Rede Bayesiana para calcular a Probabilidade Total da nota ser satisfatória dado a união das interseções entre as probabilidades da nota ser satisfatória ou não satisfatória, dado o Estilos de Aprendizagem : $P(B) = P(B | ATI) + P(B | REF)$, conforme demonstra a equação 4.1.

$$P(B) = P(B \cap ATI) + P(B \cap REF) \quad (4.1)$$

O calculo da Probabilidade Total é dado pela seguinte equação:

$$P(B) = P(B|ATI)P(ATI) + P(B|REF)P(REF). \quad (4.2)$$

Cálculo da Probabilidade Total da nota ser satisfatória aplicando a equação 4.1:

$$P(B) = P(B|ATI)P(ATI) + P(B|REF)P(REF)$$

$$P(B) = (0,2)(0,5) + (0,4)(0,5)$$

$$P(B) = 0,3$$

Cálculo da Probabilidade Total da nota ser não satisfatórias aplicando a equação 4.1:

$$P(R) = P(R|ATI)P(ATI) + P(R|REF)P(REF)$$

$$P(R) = (0,8)(0,5) + (0,6)(0,5)$$

$$P(R) = 0,7$$

Sabendo que o valor da Probabilidade Total da nota ser satisfatória é de 0,3, é possível determinar qual a probabilidade de se selecionar uma CEA composta pelo Estilo de Aprendizagem *ativo* ou *reflexivo* na Rede Bayesiana, aplicando a Regra de Bayes, conforme mostram os cálculos 4.3 e 4.4.

Dado o Estilo de Aprendizagem ser Ativo Satisfatório:

$$P(ATI|B) = \frac{P(B|ATI)P(ATI)}{P(B)} = \frac{(0,2)(0,5)}{0,3} = 0,333 \rightarrow 33,3\% \quad (4.3)$$

Dado o Estilo de Aprendizagem ser Reflexivo Satisfatório:

$$P(REF|B) = \frac{P(B|REF)P(REF)}{P(B)} = \frac{(0,4)(0,5)}{0,3} = 0,666 \rightarrow 66,6\% \quad (4.4)$$

Sabendo que o valor da Probabilidade Total da nota ser não satisfatórias é de 0,7, também é possível determinar qual a probabilidade do Estilo de Aprendizagem obter uma nota abaixo de 60, conforme os cálculos 4.5 e 4.6.

Dado o estilo de aprendizagem ser Ativo Não Satisfatório:

$$P(ATI|R) = \frac{P(R|ATI)P(ATI)}{P(R)} = \frac{(0,8)(0,5)}{0,7} = 0,571 \rightarrow 57,1\% \quad (4.5)$$

Dado o estilo de aprendizagem ser Reflexivo Não Satisfatório:

$$P(REF|R) = \frac{P(R|REF)P(REF)}{P(R)} = \frac{(0,6)(0,5)}{0,7} = 0,429 \rightarrow 42,9\% \quad (4.6)$$

Com base nos valores calculados, a Rede Bayesiana pode prever qual é o possível Estilo de Aprendizagem do Estudante, considerando o de maior probabilidade. Neste

exemplo, o provável estilo de aprendizagem do estudante na dimensão processamento é o reflexivo com a probabilidade de 66,6%, conforme a figura 5.

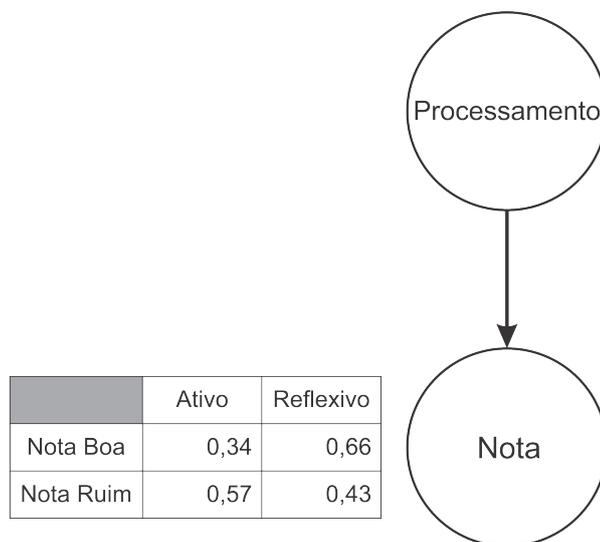


Figura 5 – Rede Bayesiana para detecção do Estilo de Aprendizagem da dimensão Processamento com as relações finais de probabilidades

A presente proposta mostra grande aderência ao modelo FSMSL, conforme apresentado nesta seção. As probabilidades geradas pela Rede Bayesiana servirão para atualizar o estilo de aprendizagem probabilístico do estudante através de um algoritmo apresentado na próxima seção.

4.1.2 FUNCIONAMENTO DO ALGORITMO

O presente trabalho propõe um algoritmo baseado nas RBs para detectar o EA de um estudante em um Ambiente Virtual de Aprendizagem, composto por um Sistema de Tutoria Inteligente.

O método proposto neste trabalho é baseado no Sistema Adaptativo e Inteligente para Educação (SAIE) apresentado por (DORÇA et al., 2012). O SAIE é composto pelo Módulo do Aluno (EA probabilístico do aluno, nível cognitivo, seção de aprendizagem atual), Módulo Pedagógico (seleciona estratégia pedagógica) e Componente de Modelagem do Estudante (atualiza o EA probabilístico). Além disso, para simular o desempenho do estudante no SAIE, Dorça et al. (2012) apresenta o Processo Estocástico de Simulação de Desempenho do Estudante (PESDE).

Conforme mencionado na seção 2.1, o FSLSM apresenta 4 dimensões, cada dimensão apresenta 2 estilos de aprendizagem. Assim sendo, existem 16 Combinações de EA (CEA), que representam as estratégias pedagógicas. A cada iteração o módulo pedagógico do SAIE seleciona uma CEA utilizando Cadeia de Markov. O PESDE simula o desempenho

do aluno dada a estratégia selecionada, o EA real do aluno (parâmetro de entrada do simulador) e uma variável aleatória que define fatores externos, inerentes ao sistema. Se nota (desempenho) for insatisfatória (nota menor que 60), o módulo Componente de Modelagem do Estudante atualiza as probabilidades dos EA armazenadas no Módulo do Aluno utilizando o algoritmo *Q-Learning* de Aprendizagem por Reforço.

O método proposto modifica o Componente de Modelagem do Estudante e substitui o algoritmo de Aprendizagem por Reforço por uma Rede Bayesiana, que atualiza os Estilos de Aprendizagem probabilístico do estudante. A Rede Bayesiana é alimentada pelo histórico do desempenho do estudante.

Para explicar o funcionamento do algoritmo, será utilizado um exemplo considerando somente a dimensão Processamento do FLSM, que possui os EA Ativo e Reflexivo. Os procedimentos aqui apresentados foram estendidos para as demais dimensões.

Algoritmo 1: Ajuste do EA probabilístico utilizando Rede Bayesiana

Entrada: Nota, CEA

Saída: EA Probabilístico

```

1 início
2   Atualiza a quantidade de CEA geradas: Ativo/Reflexivo;
3   se CEA = "Ativo" então
4     | contadorAtivo++;
5   fim
6   se CEA = "Reflexivo" então
7     | contadorReflexivo++;
8   fim
9   Atualiza a quantidade de notas satisfatórias de cada CEA: Ativo/Reflexivo
10  se nota >= 60 então
11    | se CEA = "Ativo" então
12      | contadorNotaSatisfatóriaAtivo++;
13    fim
14    | se CEA = "Reflexivo" então
15      | contadorNotaSatisfatóriaReflexivo++;
16    fim
17  fim
18  Calcula probabilidades: Ativo/Reflexivo
19  probabilidadeAtivo ← contadorNotaSatisfatóriaAtivo / contadorAtivo;
20  probabilidadeReflexivo ← 1-probabilidadeAtivo;
21  probabilidadeTotal ← probabilidadeAtivo * contadorNotaSatisfatóriaAtivo +
    probabilidadeReflexivo * contadorNotaSatisfatóriaReflexivo) (Equação.
    3.8);
22  probabilidadeFinalAtivo ← (probabilidadeAtivo *
    contadorNotaSatisfatóriaAtivo) / probabilidadeTotal (Equação. 3.7);
23  retorna Atualiza EA probabilístico(probabilidadeFinalAtivo,
    1-probabilidadeFinalAtivo);
24 fim
  
```

O algoritmo 1 apresenta as modificações aplicadas ao Componente de Modelagem do Estudante. O procedimento recebe uma nota que representa o desempenho do aluno e a CEA (estratégia pedagógica que resultou neste desempenho). Em seguida, o algoritmo atualiza os contadores de EA Ativo e EA Reflexivo, respectivamente (*linha 1*).

Em seguida, as variáveis “*contadorAtivo*” e “*contadorReflexivo*” armazenam a soma das CEAs selecionadas que possuem os EA Ativo e Reflexivo (*linha 2 à linha 8*). O próximo procedimento é contabilizar a quantidade de notas satisfatórias retornadas pelas CEAs que contém o EA Ativo (“*contadorNotaSatisfatóriaAtivo*”) e CEAs contendo EA Reflexivo (“*contadorNotaSatisfatóriaReflexivo*”) (*linha 9 à linha 17*). A Rede Bayesiana é definida a partir das notas satisfatórias, ou seja, calcula-se a probabilidade de se obter uma nota “satisfatória” selecionando a CEA com EA Ativo, sendo o valor de tal probabilidade complementar à probabilidade de se obter uma nota “satisfatória” selecionando CEA com EA Reflexivo (*linhas 19 e 20*).

Os passos seguintes calculam a probabilidade total (*linha 21*), aplicando a equação 4.1 e em seguida executa o teorema de Bayes (*linha 22*), aplicando a equação 3.7. O valor obtido (“*probabilidadeFinalAtivo*”) indica a probabilidade de obter uma nota satisfatória selecionando CEA com EA Ativo. Como as probabilidades de EA de uma mesma dimensão são complementares, a probabilidade de se obter uma nota satisfatória selecionando CEA com EA Reflexivo é dada por: $1 - \text{probabilidadeFinalAtivo}$ (*linha 23*). Por fim, os valores das probabilidades obtidos são utilizados para atualizar o EA probabilístico contido no Módulo do Aluno do SAIE.

É importante ressaltar que este procedimento é estendido para todas as dimensões do FSLSM. Para simplificar e facilitar o entendimento, apenas a dimensão Processamento foi apresentada no algoritmo 1, uma vez que, para as demais dimensões, o procedimento é similar.

Conforme apresentado no algoritmo 1, o método recebe de entrada a CEA selecionada e a nota gerada a partir desta CEA. Em seguida, as variáveis “*contadorAtivo*” e “*contadorReflexivo*” são atualizadas e irão armazenar a quantidade de CEA selecionadas com o EA Ativo e o EA Reflexivo, respectivamente. Posteriormente, se nota for satisfatória, atualiza-se as variáveis “*contadorNotaSatisfatóriaAtivo*” e “*contadorNotaSatisfatóriaReflexivo*” que armazenam a quantidade de notas satisfatórias geradas a partir de CEA com EA Ativo e EA Reflexivo, respectivamente.

Os resultados obtidos pelo algoritmo 1 abriu precedentes para uma discussão sobre o fator determinístico das probabilidades dos estilos de aprendizagem. O procedimento bayesiano seleciona o EA do estudante com maior probabilidade, não considerando fatores aleatórios, convergindo de forma mais rápida, estabilizando em valores com resultados bons, mas não obtendo valores ótimos. As probabilidades satisfatórias obtidas pelos resultados apresentam um alto fator determinístico, pois buscam padrões entre as médias das notas,

caracterizando um valor máximo local, desconsiderando o valor máximo global.

Dorça et al. (2012) também considera esse fator determinístico em seu trabalho. A taxa de conversão do algoritmo de *Q-learning* é alta e a obtenção dos resultados é mais rápida, obtendo resultados previsíveis, descartando fatores aleatórios.

O fator estocástico dessa proposta é determinante para o alcance dos objetivos da presente pesquisa, pois é necessário levar em consideração todos os fatores que levam a determinação do melhor estilo de aprendizagem para estudantes com perfis diferentes. Para isso o procedimento deve apresentar métodos para se adaptar de forma menos previsível aos diferentes tipos de estudantes, caracterizando um procedimento flexível e adaptativo.

A solução para a obtenção de valores não determinísticos é a aplicação de técnica de Cadeia de Markov para seleção do EA do estudante. Dorça et al. (2012) também utiliza a mesma técnica para alcançar resultados estocásticos, tornando o procedimento menos previsível e mais adaptável.

Conforme apresentado na seção 3.4, a Cadeia de Markov tem a propriedade a atualizar valores como uma máquina de estados, dando maior probabilidade de seleção para o estado com maior valor ao invés de escolher de forma deliberada o estado com maior probabilidade. Esse procedimento dá maior chance de escolher o EA com maior probabilidade mas não descarta a escolha do EA de probabilidade menor.

As Cadeias de Markov são utilizadas para prever estados de uma determinada atividade que está em execução, identificando o estado atual, independente de sua origem ou destino. De acordo com Meyn e Tweedie (2012), uma Cadeia de Markov utiliza uma sequência de variáveis aleatórias de um universo finito, funcionando como uma máquina de estados onde as transições e atualizações são estocásticas.

O método markoviano seleciona as duas probabilidades de cada dimensão calculadas pela Rede Bayesiana e atribui um valor de transição entre os estados. Este valor de transição é dado pela geração aleatória de um número entre 0 à 1. Caso o número gerado seja menor ou igual ao EA com maior probabilidade, a Cadeia de Markov atualiza seu estado, selecionando a maior probabilidade, caso contrário, seleciona o EA com a menor probabilidade, conforme demonstrado na figura 6.

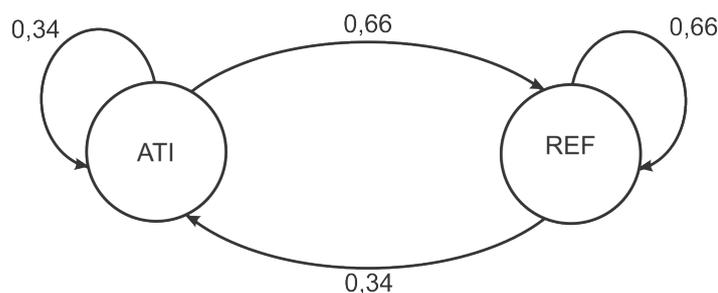


Figura 6 – Cadeia de Markov para seleção aleatória do estilo de aprendizagem

De acordo com o figura 6, a Cadeia de Markov incorpora o fator não determinístico aos resultados, dando maior probabilidade de escolher o EA com o valor probabilístico maior, não descartando as chances de escolher o EA com o valor probabilístico menor. A combinação da técnica de Rede Bayesiana com a de Cadeia de Markov apresenta uma otimização do processo de detecção do EA probabilístico, atribuindo um fator estocástico aos resultados, impedindo que o algoritmo estabilize de maneira prematura, alcançando melhores resultados no procedimento de seleção de CEAs para o estudante.

Os resultados apresentados na próxima seção confirmam a poder de adaptação da presente proposta comparada à da literatura, comprovando a grande eficiência da combinação das técnicas de Redes Bayesianas com Cadeia de Markov.

5 Resultados

Esta seção apresenta o planejamento experimental adotado para avaliação dos resultados obtidos pelos algoritmos RB e (DORÇA et al., 2012). O algoritmo RB representa o método proposto neste trabalho, que utiliza uma Rede Bayesiana para ajustar os EA probabilísticos dos estudantes. O algoritmo Dorça, consiste na abordagem apresentada por Dorça et al. (2012) no qual o ajuste dos EA probabilísticas é feito utilizando algoritmo de Aprendizagem por Reforço. Todos os algoritmos analisados foram implementados com base na arquitetura do SAIE e PESDE, proposto por (DORÇA et al., 2012).

Com o planejamento do experimento e a análise estatística dos dados obtidos é possível averiguar se há diferenças significativas entre o desempenho dos algoritmos e estimar o tamanho dessas diferenças. Para cada algoritmo, foram realizadas 30 replicações para cada EA real. Dessas 30 replicações, foram computadas as médias, totalizando 16 amostras conforme a tabela 3. Os testes foram executados de maneira independente e foram avaliadas as seguintes medidas de qualidade: quantidade de notas abaixo de 60 e média das notas obtidas nas seções de aprendizagem. Para cada métrica foi aplicado o mesmo teste estatístico, buscando encontrar as diferenças significativas entre os algoritmos considerando cada uma delas.

Para cada métrica considerada, a hipótese nula indica a ausência de diferença entre os algoritmos avaliados: RB (1) e Dorça (2), contra sua hipótese alternativa de que existe diferença em pelo menos dois algoritmos. Caso os algoritmos apresentem o mesmo desempenho e não haja diferença significativa, a hipótese nula é aceita. Por outro lado, caso haja diferenças significativas no desempenho dos algoritmos avaliados a hipótese nula é rejeitada. Para a análise dos experimentos foi considerado um nível de significância de 95% o que corresponde a um valor de α igual a 0.05. Para evitar suposições de que os dados apresentam uma distribuição normal, foi utilizado o teste de *Wilcoxon Signed Rank* (MONTGOMERY, 1991). Este teste é uma alternativa onde não é possível afirmar ou justificar sobre a normalidade dos dados.

O resultado do teste de hipótese aponta para a rejeição da hipótese nula para a métrica “média das notas”. A figura 7 apresenta o p-valor e o *boxplot* das diferença entre os algoritmos. Na figura, observa-se que o p-valor entre os algoritmos RB (1) e Dorça (2) é de 0.00085, demonstrando que existem diferenças estatisticamente significativas entre eles. Analisando o gráfico, observa-se que as médias obtidas pelo algoritmo RB são superiores às médias obtidas pelo algoritmo proposto na literatura.

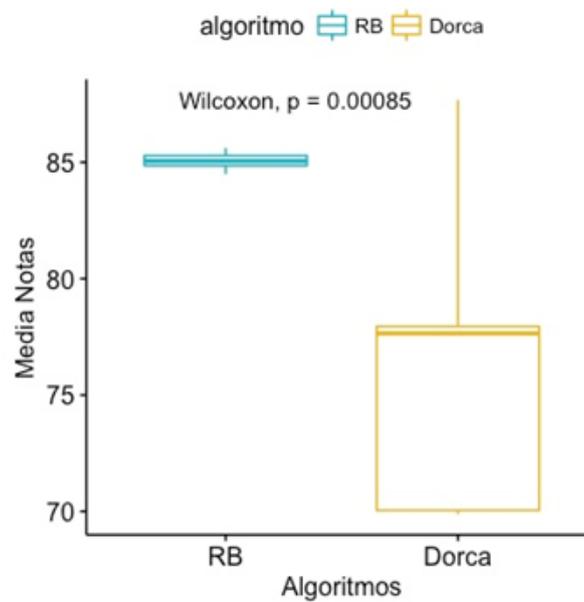


Figura 7 – *Boxplot* dos resultados dos algoritmos RB(1) e Dorça (2) referente à métrica Médias das Notas

Quanto à métrica quantidade de notas menores que 60, o algoritmo proposto tem menor variabilidade, porém a diferença entre as medianas são próximas de zero, como mostra a figura 8. Assim, o teste de *Wilcoxon* indicou que a hipótese nula não deve ser rejeitada ($p\text{-valor} > 0.05$), pois não existe evidências suficiente para isso.

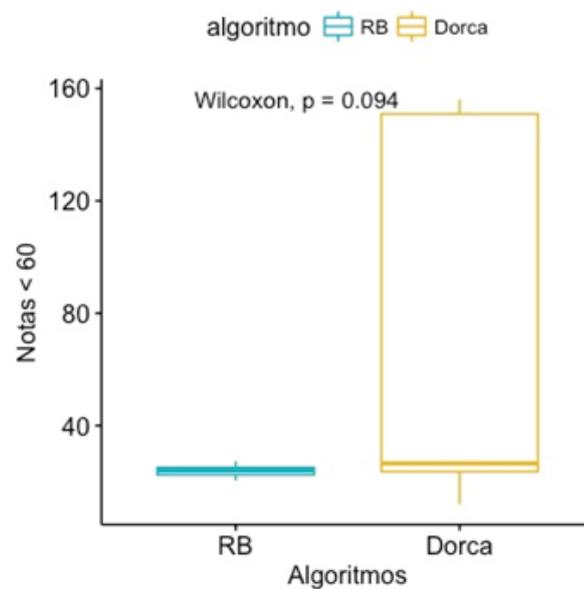


Figura 8 – *Boxplot* dos resultados dos algoritmos RB(1) e Dorça (2) referente à métrica Quantidade de Notas Insatisfatórias (notas <60).

A tabela 3 apresenta os resultados obtidos para ambas as métricas avaliadas, para os 2 algoritmos avaliados. Cada linha indica os resultados obtidos dada uma CEA real

utilizada como parâmetro de entrada do PESDE. Os melhores resultados estão destacados na tabela. Os resultados da tabela corroboram com as análises estatísticas realizadas, demonstrando superioridade do método proposto em relação às médias das notas obtidas durante as seções de aprendizagem.

Tabela 3 – Número de notas abaixo de 60 e média das notas obtidas pelos algoritmos RB(1) e Dorça(2) - Média das 30 execuções

CEA Real	Notas < 60		Médias das Notas	
	RB (1)	Dorça (2)	RB (1)	Dorça (2)
A - I - Ve - Seq	22.03	14.56	85.42	86.91
A - I - Vi - Seq	24.96	20.66	84.96	78.29
A - S - Ve - G	24.69	20.33	85.03	78.22
A - S - Vi - G	23.73	156.06	84.88	69.88
A - S - Ve - Seq	24.36	24.60	84.85	77.63
A - S - Vi - Seq	27.36	153.66	84.49	70.06
R - I - Ve - G	21.96	152.73	85.29	69.98
R - I - Vi - G	23.00	24.69	85.10	77.83
R - I - Ve - Seq	20.50	25.96	85.61	77.85
R - S - Vi - Seq	24.50	149.89	85.14	70.00
A - I - Ve - G	26.13	153.03	84.58	70.03
R - S - Ve - Seq	26.69	27.13	84.70	77.66
R - S - Vi - G	25.39	150.26	84.84	70.05
R - S - Ve - G	22.63	24.89	85.39	77.72
R - I - Vi - Seq	22.80	33.56	85.07	77.09
A - I - Vi - G	21.86	12.00	85.28	87.67

Na tabela 3 é possível verificar que o algoritmo proposto apresenta baixa variabilidade nos resultados e um melhor desempenho do algoritmo nas métricas analisadas. O algoritmo proposto mostrou estabilidade nos resultados, independente do EA real do estudante.

Analisando as notas abaixo de 60, apenas em quatro entradas o algoritmo de Redes Bayesianas apresenta pior resultado. A superioridade do algoritmo proposto também pode ser observada quanto a baixa variabilidade dos resultados, comportando-se de maneira estável.

Tal otimização proporcionou uma forma mais eficiente de detecção de EA, utilizando RBs, conforme mostram os resultados apresentados comparados ao método encontrado na literatura. Isso valida a proposta de gerar adaptações no aprendizado, atingindo os objetivos esperados.

Para enfatizar a performance do algoritmo de RB em comparação ao algoritmo proposto por Dorça et al. (2012), os gráficos 9, 10, 11 mostram o desempenho quanto aos números de iterações que os algoritmos executam para convergir ao EA do estudante.

Os testes foram realizados nas dezesseis CEAs possíveis do modelo FSLSM, onde

o barras azuis correspondem ao algoritmo de RB e os em vermelho o algoritmo proposto por (DORÇA et al., 2012).

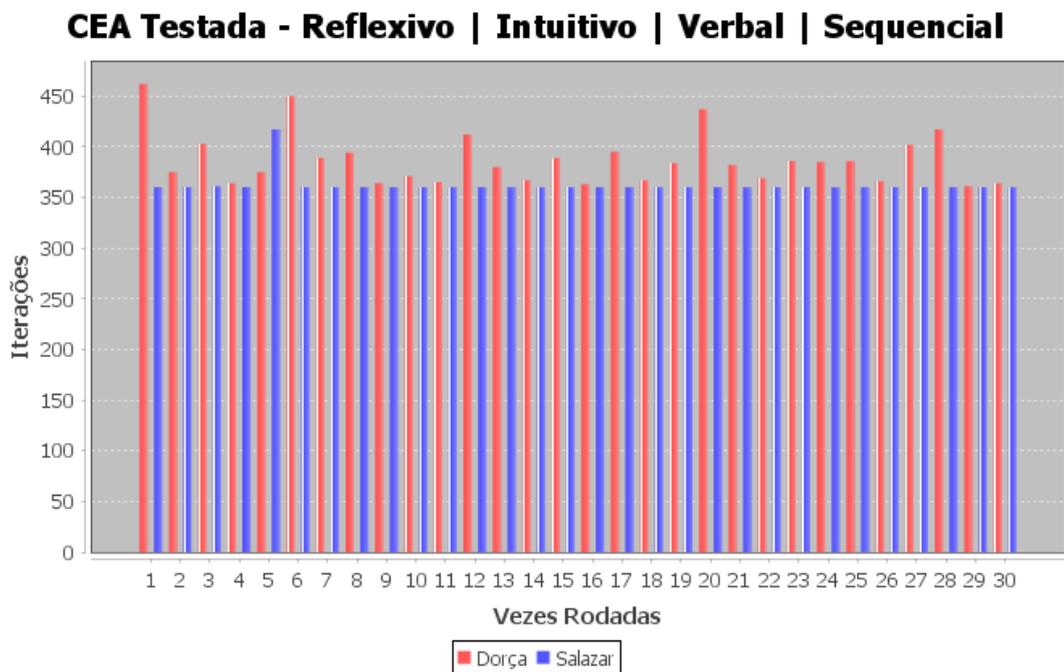


Figura 9 – Desempenho dos resultados dos algoritmos RB(1) e Dorça (2)

A figura 9 mostra o gráfico de performance dos algoritmos em testes com a CEA reflexivo, intuitivo, verbal e sequencial. Os resultados do algoritmo proposto por Dorça demoram mais para convergir e por vezes ultrapassam 450 iterações.

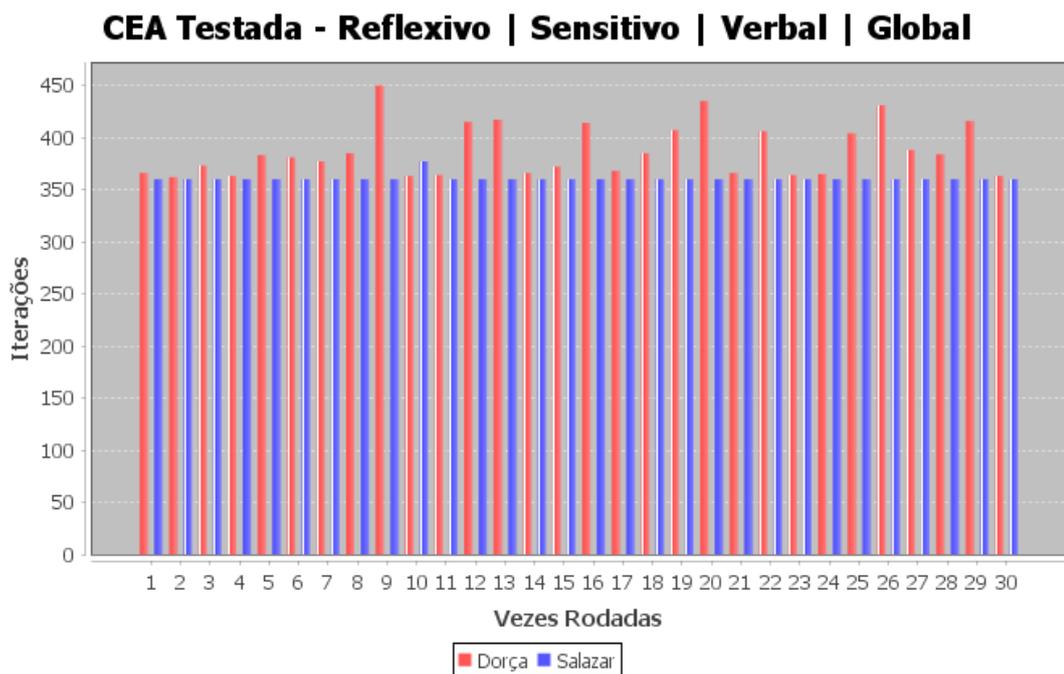


Figura 10 – Desempenho dos resultados dos algoritmos RB(1) e Dorça (2)

A figura 10 mostra o gráfico de performance dos algoritmos em testes com a CEA reflexivo, sensitivo, verbal e global. Os resultados do algoritmo de RB são próximos aos números mínimos de 360 iterações para a convergência do sistema.

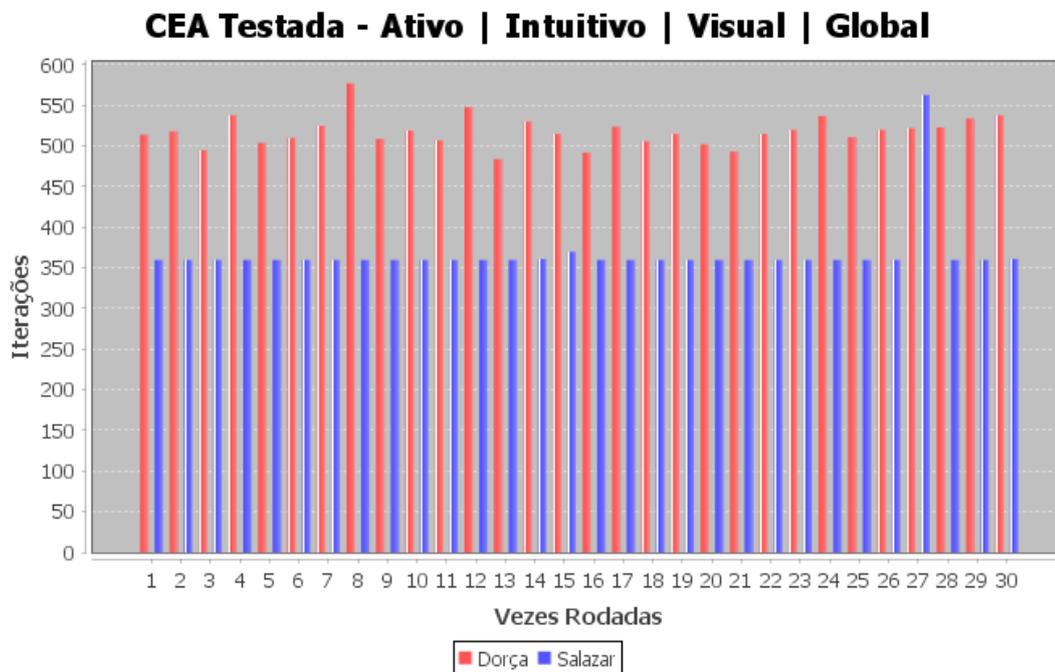


Figura 11 – Desempenho dos resultados dos algoritmos RB(1) e Dorça (2)

A figura 11 mostra o gráfico de performance dos algoritmos em testes com a CEA ativo, intuitivo, visual e global. Os resultados do algoritmo de RB são mais estáveis e possuem uma convergência mais rápida

É notável a estabilidade dos resultados gerados pelo algoritmo de RB ao longo das execuções. Os gráficos mostram a vantagem na produtividade nas sessões de aprendizagem onde é exigido o mínimo de 360 iterações para o sistema convergir ao EA do estudante.

Em alguns resultados o algoritmo de RB conclui as iterações próximo ou até em 360 sessões de aprendizagem, evidenciando maior precisão e velocidade.

6 Conclusão

O objetivo principal deste trabalho foi otimizar a detecção de Estilos de Aprendizagem para possibilitar a oportunidade de oferecer materiais didáticos mais adaptados aos EA dos estudantes, caracterizando um sistema inteligente e adaptativo em Ambientes Virtuais de Aprendizagem, tomando como incentivo o trabalho desenvolvido por (DORÇA et al., 2012).

Tal otimização proporcionou uma nova forma de detecção de EA, utilizando um algoritmo de Rede Bayesiana, que foi comparado com resultados comprovados no trabalho de Dorça et al. (2012), onde os testes encontrados no capítulo 5 demonstram equivalência entre as duas propostas, porém maior eficiência da Rede Bayesiana, promovendo maior velocidade e estabilidade na convergência dos resultados. Isso determina a validade da proposta em detectar automaticamente os estilos de aprendizagem de estudantes em Ambientes Virtuais de Aprendizagem, atingindo os objetivos esperados.

Um aspecto importante a ser destacado nessa pesquisa, consiste no uso de Redes Bayesianas em processos de inferência probabilística, que demonstrou ser largamente eficiente quanto a detecção de EA de estudantes em ambientes virtuais de aprendizagem. Essa eficiência dá-se pela robustez probabilística que as Redes Bayesianas possuem ao utilizarem dados já existentes para inferir resultados prováveis.

Os resultados obtidos no presente trabalho foram satisfatórios, superando as expectativas iniciais que geravam dúvidas quanto ao sucesso da aplicação de Redes Bayesianas para detecção de EA. Contudo, o modelo proposto se mostrou estável e aderente aos Sistemas Adaptativos e Inteligentes para Educação, provando a viabilidade da proposta.

Os resultados também demonstraram o fator não determinístico da proposta, onde as saídas obtidas se mostraram aleatórias ao conjunto de parâmetros de entrada do algoritmo. Isso se deve a combinação das técnicas de Redes Bayesianas com Cadeia de Markov, que adicionou um fator estocástico à proposta, mostrando ser eficiente para o tratamento de dados em situações de incerteza.

6.1 CONTRIBUIÇÕES

A principal contribuição deste trabalho considera uma abordagem capaz de identificar as preferências individuais e cognitivas de estudantes em ambientes virtuais de aprendizagem e atualizar automaticamente seus estilos de aprendizagem probabilístico. Tal abordagem utiliza técnicas de Redes Bayesianas, baseadas em informações contida no modelo do estudante para atualizar suas probabilidades do estilo de aprendizagem

probabilístico e assim determinar qual a melhor combinação de estilos de aprendizagem adaptada às preferências de um aprendiz.

A condução do trabalho buscou mostrar a importância dos conceitos de referência para a pesquisa, tanto da área técnica como educacional, embasando teorias que auxiliaram no processo de construção da proposta. Neste sentido, ficou evidente a necessidade da oferta de ambientes educacionais adaptados às preferências dos estudantes.

Um destaque na pesquisa foi o desenvolvimento de um modelo de Redes Bayesianas para a detecção dos Estilos de Aprendizagens dos estudantes em AVA. O modelo se mostrou eficiente para a atualização dos EA probabilísticos no Modelo do Estudante. A velocidade e estabilidade da presente proposta gerou maior confiabilidade para oferecer material adaptado aos estudantes e assim, combatendo problemas críticos em EaD como a evasão e desinteresse dos seus participantes.

Outra questão importante a ser destacada foi a associação de Redes Bayesianas com Cadeias de Markov. Esta combinação de técnicas proporcionou resultados não determinísticos, demonstrando que a proposta tem potencial de implantação em ambientes que envolvem condições de incerteza.

Finalizando, a pesquisa mostrou validade e importância da utilização do método de simulação computacional como ferramenta de construção e validação de um modelo computacional. A aplicação de técnicas probabilísticas permitiu desenvolver uma aplicação educacional para a personalização do ensino a distância.

6.2 TRABALHOS FUTUROS

Os resultados obtidos no presente trabalho apontam para um futuro promissor em pesquisas na área de detecção de estilos de aprendizagem em ambientes virtuais de aprendizagem. As técnicas que proporcionaram tais resultados se mostraram eficientes e aderentes a outras técnicas e ambientes operacionais.

Tendo em vista a boa performance da proposta, os trabalhos futuros apontam para três vertentes:

- O aprimoramento da Rede Bayesiana para otimizar a performance dos resultados como ampliação dos parâmetros probabilísticos como aplicação das notas não satisfatórias à rede, bem como aplicação da técnica de Cobertura de Markov nas relações probabilísticas *a priori* da Rede Bayesiana, utilizados para aumentar a precisão na detecção dos estilos de aprendizagem.
- A aplicação da presente proposta utilizando dados reais de estudante em ambientes virtuais de aprendizagem ao invés de utilizar simulação computacional, fazendo uso

de *logs* de usuário e outras formas de obtenção de dados para viabilizar a proposta como ferramenta real.

- Implementar técnicas de Redes Bayesianas para a recomendação de objetos de aprendizagem para estudantes em ambientes virtuais de aprendizagem, baseados nos estilos de aprendizagem detectados.

Referências

- ABED. br (2015) censo ead. br/organização associação brasileira de educação a distância. São Paulo: Pearson Education do Brasil, 2015. Citado na página 18.
- AL-AZAWEI, A.; BADI, A. State of the art of learning styles-based adaptive educational hypermedia systems (LS-BAEHSs). *International Journal of Computer Science & Information Technology*, Academy & Industry Research Collaboration Center (AIRCC), v. 6, n. 3, p. 1, 2014. Citado 2 vezes nas páginas 31 e 41.
- ALMEIDA, M. E. B. de. Educação a distância na internet: abordagens e contribuições dos ambientes digitais de aprendizagem. *Educação e pesquisa*, SciELO Brasil, v. 29, n. 2, p. 327–340, 2003. Citado na página 21.
- AMIR, E. S.; SUMADYO, M.; SENSUSE, D. I.; SUCAHYO, Y. G.; SANTOSO, H. B. Automatic detection of learning styles in learning management system by using literature-based method and support vector machine. In: IEEE. *Advanced Computer Science and Information Systems (ICACSIS), 2016 International Conference on*. [S.l.], 2016. p. 141–144. Citado na página 33.
- ATUNCAR, G. S. Conceitos básicos de processos estocásticos. *Departamento de Estatística. Universidade Federal de Minas Gerais. Belo Horizonte*, 2011. Citado na página 42.
- AZOURY, K. S.; MILLER, B. L. A comparison of the optimal ordering levels of Bayesian and non-Bayesian inventory models. *Management science*, INFORMS, v. 30, n. 8, p. 993–1003, 1984. Citado na página 41.
- BARBER, D. *Bayesian reasoning and machine learning*. [S.l.]: Cambridge University Press, 2012. Citado na página 44.
- BELLONI, M. L. *Educação a distância*. [S.l.]: Autores Associados, 2006. Citado na página 16.
- BELLOT, D. *Learning Probabilistic Graphical Models in R*. [S.l.]: Packt Publishing Ltd, 2016. Citado na página 39.
- BERINGS, M. G. M. C.; POELL, R. F.; SIMONS, P. R.-J. Conceptualizing on-the-job learning styles. *Human Resource Development Review*, Sage Publications Sage CA: Thousand Oaks, CA, v. 4, n. 4, p. 373–400, 2005. Citado na página 29.
- BLOOM, B. S.; COLLEGE, C. of; EXAMINERS, U. *Taxonomy of educational objectives*. [S.l.]: Longmans, Green New York, 1964. v. 2. Citado na página 28.
- BORGES, M. K. Educação semipresencial: desmistificando a educação a distância. In: *Anais do 12º Congresso Internacional de Educação à Distância. Florianópolis, Setembro*. [S.l.: s.n.], 2005. Citado na página 24.
- BOTELHO, C. A.; PIMENTEL, E. P.; SENGER, H.; STIUBIENER, I. Personalização em Sistemas de Gerenciamento da Aprendizagem em Conformidade com o Padrão SCORM.

In: *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*. [S.l.: s.n.], 2009. v. 1, n. 1. Citado na página 27.

BRASIL, C. Subchefia para Assuntos Jurídicos. 2006. Citado na página 16.

BREFELD, U.; SCHEFFER, T. Co-EM support vector learning. In: ACM. *Proceedings of the twenty-first international conference on Machine learning*. [S.l.], 2004. p. 16. Citado na página 44.

BRUSILOVSKY, P. Methods and techniques of adaptive hypermedia. *User modeling and user-adapted interaction*, Springer, v. 6, n. 2-3, p. 87–129, 1996. Citado na página 25.

BRUSILOVSKY, P. Adaptive hypermedia: From intelligent tutoring systems to Web-based education. In: SPRINGER. *Intelligent tutoring systems*. [S.l.], 2000. v. 2000, p. 1–7. Citado 3 vezes nas páginas 23, 24 e 26.

BRUSILOVSKY, P.; MILÁN, E. User models for adaptive hypermedia and adaptive educational systems. In: *The adaptive web*. [S.l.]: Springer, 2007. p. 3–53. Citado na página 18.

BRUSILOVSKY, P.; PEYLO, C. Adaptive and intelligent web-based educational systems. *International Journal of Artificial Intelligence in Education (IJAIED)*, v. 13, p. 159–172, 2003. Citado na página 23.

CANDOTTI, C. T.; GELLER, M.; SILVEIRA, S. R.; MARQUES, E. M.; SANTANA, M. B. Sistema hipermídia adaptativo baseado em estilos cognitivos. *RENOTE*, v. 4, n. 2, 2006. Citado na página 22.

CHARNIAK, E. Bayesian networks without tears. *AI magazine*, v. 12, n. 4, p. 50, 1991. Citado na página 40.

CLARKE, A. B.; DISNEY, R. L. *Probabilidade e processos Estocásticos*. [S.l.]: LTC, 1979. Citado na página 42.

COELHO, M. d. L. A evasão nos cursos de formação continuada de professores universitários na modalidade de educação distância via internet. *Universidade Federal de Minas Gerais*, 2002. Citado na página 18.

COPPIN, B. Inteligência artificial/ben coppin; tradução e revisão técnica jorge duarte pires valério. *Rio de Janeiro: LTC*, 2010. Citado na página 45.

CORREIA, M. S. B. B. Probabilidade e estatística. 2003. Citado na página 36.

COSTA, M. T. C. d. et al. Uma arquitetura baseada em agentes para suporte ao ensino à distância. Florianópolis, SC, 1999. Citado na página 26.

DORÇA, F. A. Um Sistema Inteligente Multiagente para Educação à Distância Apoiado em Web. p. 1–198, 2004. Citado na página 32.

DORÇA, F. A. et al. Uma abordagem estocástica baseada em aprendizagem por reforço para modelagem automática e dinâmica de estilos de aprendizagem de estudantes em sistemas adaptativos e inteligentes para educação a distância. Universidade Federal de Uberlândia, 2012. Citado 20 vezes nas páginas 17, 23, 24, 27, 28, 31, 32, 35, 42, 44, 45, 46, 47, 48, 52, 55, 57, 59, 60 e 62.

- DUNN, R.; DUNN, K.; PRICE, G. E. et al. Identifying individual learning styles. *Student learning styles: Diagnosing and prescribing programs*, National Association of Secondary School Principals Reston, VA, p. 39–54, 1979. Citado na página 29.
- DUNN, R. S.; DUNN, K. J. *Teaching students through their individual learning styles: A practical approach*. [S.l.]: Prentice Hall, 1978. Citado na página 16.
- DUTRA, R. L. d. S.; TAROUÇO, L. M. R. Objetos de aprendizagem: uma comparação entre scorm e ims learning design. *RENOTE: revista novas tecnologias na educação [recurso eletrônico]*. Porto Alegre, RS, 2006. Citado na página 26.
- EUSTACE, K. Educational value of e-learning in conventional and complementary computing education. *Proceedings of the 16th National Advisory Committee on Computing Qualifications (NACCQ), Palmerston North, New Zealand*, p. 53–62, 2003. Citado na página 22.
- FELDER, R. M. How students learn: Adapting teaching styles to learning styles. In: IEEE. *Frontiers in Education Conference, 1988., Proceedings*. [S.l.], 1988. p. 489–493. Citado 2 vezes nas páginas 30 e 33.
- FELDER, R. M.; HENRIQUES, E. R. Learning and teaching styles in foreign and second language education. *Foreign language annals*, Wiley Online Library, v. 28, n. 1, p. 21–31, 1995. Citado na página 29.
- FELDER, R. M.; HENRIQUES, E. R. Learning and teaching styles in foreign and second language education. *Foreign Language Annals*, v. 28, n. 1, p. 21–31, 1995. ISSN 0015718X. Citado na página 30.
- FELDER, R. M.; SILVERMAN, L. K.; OTHERS. Learning and teaching styles in engineering education. *Engineering education*, v. 78, n. 7, p. 674–681, 1988. Citado 2 vezes nas páginas 29 e 31.
- FELDER, R. M.; SPURLIN, J. Applications, reliability and validity of the index of learning styles. *International journal of engineering education*, v. 21, n. 1, p. 103–112, 2005. Citado na página 32.
- GARCÍA, P.; AMANDI, A.; SCHIAFFINO, S.; CAMPO, M. Evaluating Bayesian networks' precision for detecting students' learning styles. *Computers Education*, Elsevier, v. 49, n. 3, p. 794–808, 2007. Citado 4 vezes nas páginas 16, 31, 32 e 33.
- GARDINER, C. W. *Handbook of Stochastic Methods: For Physics, Chemistry and the Natural Sciences, H. Haken, Ed.* [S.l.]: Springer, 1983. Citado 2 vezes nas páginas 36 e 42.
- GRAF, S. Advanced adaptivity in learning management systems by considering learning styles. In: IEEE COMPUTER SOCIETY. *Proceedings of the 2009 IEEE/WIC/ACM International Joint Conference on Web Intelligence and Intelligent Agent Technology-Volume 03*. [S.l.], 2009. p. 235–238. Citado 2 vezes nas páginas 23 e 27.
- GRAF, S.; KINSHUK, P. An approach for detecting learning styles in learning management systems. In: IEEE. *Advanced Learning Technologies, 2006. Sixth International Conference on*. [S.l.], 2006. p. 161–163. Citado 2 vezes nas páginas 17 e 23.

- HAMMOND, T. R.; O'BRIEN, C. M. An application of the Bayesian approach to stock assessment model uncertainty. *ICES Journal of Marine Science*, Oxford University Press, v. 58, n. 3, p. 648–656, 2001. Citado na página 38.
- HORNY. Bayesian Networks. 2014. Citado 2 vezes nas páginas 39 e 40.
- HUNTER, B. Learning in the virtual community depends upon changes in local communities. *Building virtual communities: Learning and change in cyberspace*, Cambridge University Press Cambridge, England, p. 96–126, 2002. Citado na página 15.
- IGLESIAS, A.; MART'INEZ, P.; ALER, R.; FERNÁNDEZ, F. Learning teaching strategies in an adaptive and intelligent educational system through reinforcement learning. *Applied Intelligence*, Springer, v. 31, n. 1, p. 89–106, 2009. Citado na página 44.
- JENSEN, F. V. *An introduction to Bayesian networks*. [S.l.]: UCL press London, 1996. v. 210. Citado na página 38.
- JUNG, C. G. *Tipos psicológicos*. [S.l.]: Editora Vozes Limitada, 1971. Citado na página 30.
- KEEFE, J.; JENKINS, J. *Instruction and the learning environment*. [S.l.]: Routledge, 2013. Citado na página 29.
- KOLB, D. A. Experiential Learning: Experience as The Source of Learning and Development. *Prentice Hall, Inc.*, n. 1984, p. 20–38, 1984. ISSN 00178012. Citado 3 vezes nas páginas 28, 29 e 30.
- LO, J.-J.; CHAN, Y.-C.; YEH, S.-W. Designing an adaptive web-based learning system based on students' cognitive styles identified online. *Computers & Education*, Elsevier, v. 58, n. 1, p. 209–222, 2012. Citado na página 27.
- LOGAN, K. R.; KEEFE, E. B. A comparison of instructional context, teacher behavior, and engaged behavior for students with severe disabilities in general education and self-contained elementary classrooms. *Journal of the Association for Persons with Severe Handicaps*, SAGE Publications Sage CA: Los Angeles, CA, v. 22, n. 1, p. 16–27, 1997. Citado 2 vezes nas páginas 28 e 29.
- López Puga, J.; García García, J.; Fuente Sánchez, L. de la; la Fuente Solana, E. I. Las redes bayesianas como herramientas de modelado en psicología. *Anales de psicología*, Universidad de Murcia, v. 23, n. 2, 2007. Citado na página 32.
- LUGO, G. G.; RODR, L.-f.; GARC, R. I. Behavioral Patterns for Automatic Detection of Learning Styles in Learning Management Systems : a Case Study. n. 2015, p. 69–77, 2015. Citado na página 32.
- LÉVY, P.; COSTA, C. I. da. *tecnologias da inteligência, As*. [S.l.]: Editora 34, 1993. Citado na página 15.
- LÉVY, P. P.; OTTAWA, U. Un Programme de recherche pour l' économie de l' information. p. 1–45, 2006. Citado na página 15.
- MACIEL, C.; BACKES, E. M. Objetos de aprendizagem, objetos educacionais, repositórios e critérios para sua avaliação. *Ambientes Virtuais de Aprendizagem*, p. 161–198, 2012. Citado na página 16.

- MARQUES, R.; DUTRA, I. Redes Bayesianas: o que são, para que servem, algoritmos e exemplos de aplicações. *Coppe Sistemas–Universidade Federal do Rio de ...*, p. 1–22, 2002. Disponível em: <<http://www.cos.ufrj.br/~ines/courses/cos740/leila/cos740/Bayesianas.p>>. Citado 3 vezes nas páginas 37, 39 e 41.
- MARTINS, M. E. G. Introdução à Probabilidade e à Estatística Com complementos de Excel. 2005. Citado na página 36.
- MARTINS, W.; AFONSECA, U. R.; NALINI, L. E. G.; GOMES, V. M. Tutoriais inteligentes baseados em aprendizado por reforço: concepção, implementação e avaliação empírica. In: *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*. [S.l.: s.n.], 2007. v. 1, n. 1, p. 550–559. Citado na página 24.
- MELIÁN, B.; Moreno Perez, J.; Marcos Moreno-Vega, J. Metaheuristics: A global view. *Inteligencia Artificial*, v. 7, n. 19, p. 7–28, 2003. ISSN 1137-3601. Citado na página 37.
- MELOROSE, J.; PERROY, R.; CAREAS, S. *No Title No Title*. [S.l.: s.n.], 2015. v. 1. ISSN 1098-6596. ISBN 9788578110796. Citado na página 37.
- MEYN, S. P.; TWEEDIE, R. L. *Markov chains and stochastic stability*. [S.l.]: Springer Science & Business Media, 2012. Citado 3 vezes nas páginas 42, 43 e 55.
- MILLIGAN, C. Delivering staff and professional development using virtual learning environments. *The Role of Virtual Learning Environments in the Online Delivery of Staff Development. Institute for Computer Based Learning, Heriot-Watt University, Riccarton, Edinburgh EH14-4AS*, 1999. Citado na página 22.
- MONTEIRO, L. H. A. *Sistemas dinâmicos*. [S.l.]: Editora Livraria da Física, 2006. Citado na página 42.
- MONTGOMERY, D. C. Experiments with a single factor: the analysis of variance. *Design and analysis of experiments*, John Wiley and Sons: New York, v. 7, p. 87–89, 1991. Citado na página 57.
- MORAIS, N.; CABRITA, I. Ambientes virtuais de aprendizagem: comunicação (as) síncrona e interação no ensino superior. CETAC. MEDIA, 2008. Citado na página 21.
- NAGARAJAN, R.; SCUTARI, M.; LÈBRE, S. Bayesian networks in R. *Springer*, Springer, v. 122, p. 125–127, 2013. Citado na página 38.
- NEUFELD, E. Pearl|judea. probabilistic reasoning in intelligent systems: networks of plausible inference. series in representation and reasoning. morgan kaufmann, san mateo1988, xix+ 552 pp. *The Journal of Symbolic Logic*, Cambridge University Press, v. 58, n. 2, p. 721–721, 1993. Citado na página 39.
- NUNES, C. S.; TORRES, M. K. L.; OLIVEIRA, P. C. de; NAKAYAMA, M. K. O ambiente virtual de aprendizagem Moodle: recursos para os processos de Aprendizagem Organizacional. In: *Brazilian Symposium on Computers in Education (Simpósio Brasileiro de Informática na Educação-SBIE)*. [S.l.: s.n.], 2012. v. 23, n. 1. Citado na página 21.
- PALOMINO, C. E. G.; OTHERS. Modelo de sistema tutorial inteligente para ambientes virtuais de aprendizagem baseado em agentes. 2013. Citado na página 24.

PAPOULIS, A.; PILLAI, S. U. *Probability, random variables, and stochastic processes*. [S.l.]: Tata McGraw-Hill Education, 2002. Citado na página 42.

PEREIRA, A. T. C.; SCHMITT, V.; DIAS, M. Ambientes virtuais de aprendizagem. *AVA-Ambientes Virtuais de Aprendizagem em Diferentes Contextos*. Rio de Janeiro: Editora Ciência Moderna Ltda, p. 4–22, 2007. Citado na página 21.

PHOBUN, P.; VICHEANPANYA, J. Adaptive intelligent tutoring systems for e-learning systems. *Procedia-Social and Behavioral Sciences*, Elsevier, v. 2, n. 2, p. 4064–4069, 2010. Citado na página 24.

PIAZZI, P. Aprendendo inteligência. *Brasil: Ed. Vida e Consciência*, 2007. Citado na página 16.

PIOMBO, C.; BATATIA, H.; AYACHE, A. A framework for adapting instruction to cognitive learning styles. In: IEEE. *Advanced Learning Technologies, 2003. Proceedings. The 3rd IEEE International Conference on*. [S.l.], 2003. p. 434–435. Citado na página 41.

PUGA, J. L.; GARCÍA, J. G. Sistemas de tutorización inteligente basados en redes bayesianas. *REMA Revista electronica de metodologia aplicada*, v. 13, n. 1, p. 13–25, 2008. Citado 2 vezes nas páginas 31 e 32.

RAMOS, J. L. C. Uma abordagem preditiva da evasão na educação a distância a partir dos construtos da distância transacional. 2016. Citado na página 18.

RIBEIRO, E. N.; MENDONÇA, G. d. A.; MENDONÇA, A. F. A importância dos ambientes virtuais de aprendizagem na busca de novos domínios da ead. In: *Anais do 13º Congresso Internacional de Educação a Distância*. Curitiba, Brasil. [S.l.: s.n.], 2007. Citado na página 17.

RODRIGUES, L. H. S.; ASSIS, L.; VIVAS, A.; PITANGUI, C.; FALCI, S. Análise comparativa de novas abordagens para modelagem automática e dinâmica de estilos de aprendizagem em sistemas adaptativos e inteligentes para educação. n. Cbie, p. 1076, 2016. ISSN 2316-6533. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/6793>>. Citado 2 vezes nas páginas 32 e 35.

RUSSELL, S.; NORVIG, P. *INTELIGÊNCIA ARTIFICIAL, 3E.[Sl: sn], 2013*. [S.l.], 2004. Citado 7 vezes nas páginas 36, 37, 38, 39, 41, 44 e 45.

SANCHES, M. K. *Aprendizado de máquina semi-supervisionado: proposta de um algoritmo para rotular exemplos a partir de poucos exemplos rotulados*. Tese (Doutorado) — Universidade de São Paulo, 2003. Citado na página 45.

SCHMECK, R. R. Inventory of learning processes. *Student learning styles and brain behavior*, Reston, VA: Reston Publishing Company, v. 11, 1982. Citado na página 28.

SENA, E.; VIVAS, A.; ASSIS, L.; PITANGUI, C. Proposta de uma Abordagem Computacional para Detecção Automática de Estilos de Aprendizagem Utilizando Modelos Ocultos de Markov e FSLSM. p. 1126, 2016. ISSN 2316-6533. Disponível em: <<http://www.br-ie.org/pub/index.php/sbie/article/view/6798>>. Citado 3 vezes nas páginas 31, 32 e 34.

SERRA, M. R. G. Aplicações de aprendizagem por reforço em controle de tráfego veicular urbano. Florianópolis, SC, 2004. Citado na página 45.

- SHEREMETOV, L.; MENTADO, M. A. Weiss, gerhard. multiagent systems a modern approach to distributed artificial intelligence. *Computación y Sistemas*, v. 3, n. 004. Citado na página 44.
- SILVA, D. H.; DORÇA, F. A. Uma Abordagem Automática para Personalização do Processo de Ensino Baseada em Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância. *Revista Brasileira de Informática na Educação*, v. 22, n. 2, p. 1–15, 2014. Citado 2 vezes nas páginas 31 e 32.
- SOLOMAN, B. A.; FELDER, R. M. Index of learning styles questionnaire. *Retrieved March*, v. 26, p. 2003, 1999. Citado 2 vezes nas páginas 27 e 30.
- SPECHT, M.; OPPERMAN, R. ACE-adaptive courseware environment. *New Review of Hypermedia and Multimedia*, Taylor & Francis, v. 4, n. 1, p. 141–161, 1998. Citado na página 17.
- SUTTON, R. S.; BARTO, A. G. *Reinforcement learning: An introduction*. [S.l.]: MIT press Cambridge, 1998. v. 1. Citado na página 45.
- TAJRA, S. F. *Informática na Educação: novas ferramentas pedagógicas para o professor na atualidade*. [S.l.]: Érica, 2011. Citado na página 21.
- THOMPSON, J. E. *Student modeling in an intelligent tutoring system*. [S.l.], 1996. Citado na página 27.
- TURING, A. M. Computing machinery and intelligence. *Mind*, JSTOR, v. 59, n. 236, p. 433–460, 1950. Citado na página 44.
- VALLDEPERAS, E. M. *Sistema bayesiano para modelado del alumno. 2000*. Tese (Doutorado) — Tesis Doctoral. Departamento de Lenguajes y Ciencias de la Computacion. Universidade de Malaga, Malaga, Espanha. Citado na página 27.
- VAZ, D.; ZANELLA, R.; ANDRADE, S. Ambientes Virtuais: Uma nova ferramenta de ensino. *Revista iTEC*, v. 1, n. 1, p. 8–12, 2010. Citado na página 22.
- WENGER, E. Artificial intelligence and tutoring system: Computational and Cognitive Approaches to the Communication of Knowledge. *Califórnia: Morgan Kaufmann Publishers. Texto publicado na: Pátio-revista pedagógica Editora Artes Médicas Sul Ano*, v. 1, p. 19–21, 1987. Citado 3 vezes nas páginas 24, 25 e 26.
- WITTEN, I. H.; FRANK, E.; HALL, M. A.; PAL, C. J. *Data Mining: Practical machine learning tools and techniques*. [S.l.]: Morgan Kaufmann, 2016. Citado na página 44.
- WOODBERRY, O.; NICHOLSON, A. E.; KORB, K. B.; POLLINO, C. A. Parameterising Bayesian Networks. In: SPRINGER. *Australian Conference on Artificial Intelligence*. [S.l.], 2004. p. 1101–1107. Citado na página 38.